

UNIVERSIDAD AUTÓNOMA DE MADRID
ESCUELA POLITÉCNICA SUPERIOR



TRABAJO DE FIN DE GRADO

Análisis de relaciones entre tipos de personalidad y preferencias de usuario: Aplicación a sistemas de recomendación

Autora: Carolina Falcato Córdoba

Tutor: Iván Cantador Gutiérrez

Junio 2014

Resumen y palabras clave

Resumen

En los últimos años la Web ha experimentado un crecimiento incesante y cada año son más las empresas que ofrecen sus productos en internet. Por ello, a los usuarios se les hace cada vez más difícil el gestionar todos los datos disponibles, principalmente al realizar búsquedas de información en la Web. Por otra parte, las empresas compiten entre ellas por su supervivencia utilizando servicios diferenciadores que les aseguren además de mantener su propia clientela, atraer nuevos usuarios de otras empresas.

Esta situación hace que cada más sitios Web empleen Sistemas de Recomendación para ofrecer los productos o servicios que puedan ser de mayor interés a los usuarios utilizando diferentes variables relacionadas con los propios usuarios, los productos y los contextos en los que las recomendaciones se presentan y consumen. Una de estas variables es la personalidad de cada cliente, ya que se ha demostrado que existen correlaciones entre los rasgos de personalidad y las preferencias (gustos, intereses) de usuarios en diferentes dominios, y que tales correlaciones permiten mejorar recomendaciones personalizadas.

Partiendo de un trabajo de investigación previo, este Trabajo de Fin de Grado presenta varios métodos de filtrado colaborativo que tienen en cuenta la personalidad de los usuarios, así como una evaluación de los resultados de recomendación obtenidos a partir de esos métodos sobre un conjunto de datos con 22.289 perfiles extraídos de la red social Facebook y compuestos por los valores de los rasgos de personalidad según el Modelo de los Cinco Factores, y de las preferencias personales de cada usuario en varios dominios de entretenimiento: cine, música y libros.

Palabras clave

Sistemas de recomendación, filtrado colaborativo, personalidad, Modelo de los Cinco Factores, similitud entre usuarios, recomendación sobre dominios cruzados.

Abstract and keywords

Abstract

In the last years, the Web has been widely expanded, and every year more and more companies offer their products in the Internet. Therefore, users find much more difficult to manage all the available data, especially when they search for information in the Web. Moreover, companies compete with each other for their survival using differentiating services that, in addition to maintain own customers, ensure to attract additional customers from other companies.

Due to such situation, many websites use Recommender Systems to offer users with the products or services that could be more interesting, according to different user, item and contextual variables. One of these variables is the client's personality, since it has been shown that there exist certain correlations between personality traits and user preferences (tastes, interests) in different domains, and that such correlations let improve personalized recommendations.

Based on previous research work, this document presents several personality-based collaborative filtering methods, and results obtained in the evaluation of such methods on a dataset with 22.289 Facebook user profiles, composed of the Five Factor Model personality traits values and personal preferences of each user in multiple entertainment domains, namely movies, music and books.

Keywords

Recommender systems, collaborative filtering, personality, Five Factor Model, user similarity, cross-domain recommendation.

Glosario

AGR	Amabilidad (del inglés <i>Agreeableness</i>)
BFI	Inventario de preguntas de los Cinco Factores (del inglés <i>Big Five Inventory</i>)
CB	[Sistema de recomendación] basado en contenido (del inglés <i>Content Based</i>)
CF	[Sistema de recomendación de] filtrado colaborativo (del inglés <i>Collaborative Filtering</i>)
CON	Responsabilidad (del inglés <i>Conscientiousness</i>)
COS	Similitud basada en el coseno
EXT	Extraversión (del inglés <i>Extraversion</i>)
FFM	Modelo de los Cinco Factores (del inglés <i>Five Factor Model</i>)
MAE	Error Absoluto Medio (del inglés <i>Mean Absolute Error</i>)
IPIP	Inventario de personalidad (del inglés <i>International Personality Item Pool</i>)
NEU	Neuroticismo o Inestabilidad emocional (del inglés <i>Neuroticism</i>)
OPE	Apertura a la experiencia (del inglés <i>Openness</i>)
PEA	Correlación de Pearson
RMSE	Raíz del Error Cuadrático Medio (del inglés <i>Root Mean Square Error</i>)
SPE	Correlación de Spearman
SR	Sistema(s) de recomendación
TIPI	Inventario de diez factores de personalidad (del inglés <i>Ten Item Personality Inventory</i>)

Índice

1. Introducción	1
1.1. Motivación	1
1.2. Objetivos	3
1.3. Contribuciones.....	3
1.4. Estructura del trabajo.....	3
2. Trabajo relacionado: Modelado y adquisición de información sobre la personalidad ...	5
2.1. El modelo de los Cinco Factores de personalidad.....	5
2.2. Otros modelos de personalidad	8
2.3. Adquisición de la personalidad	8
3. Trabajo relacionado: Recomendación basada en personalidad	11
3.1. Sistemas de recomendación.....	11
3.2. Sistemas de recomendación sobre dominios cruzados	17
3.3. Relaciones entre preferencias y personalidad del usuario	18
3.4. Sistemas de recomendación basados en personalidad.....	22
4. Métodos de recomendación basados en personalidad propuestos.....	23
4.1. Filtrado colaborativo basado en personalidad	23
4.2. Similitud de personalidad basada en coseno	24
4.3. Similitud de personalidad basada en Pearson.....	24
4.4. Similitud de personalidad basada en Spearman	25
5. Evaluación de los métodos de recomendación propuestos	27
5.1. Conjunto de datos.....	27
5.2. Escenarios de preferencias de usuario en dominios cruzados	28
5.3. Metodología y métricas de evaluación	28
6. Resultados de evaluación obtenidos	31
6.1. Evaluación sobre dominios individuales.....	31
6.2. Evaluación sobre dominios cruzados con solapamiento	32
6.3. Evaluación sobre dominios cruzados sin solapamiento	34
6.4. Discusión.....	37
7. Conclusiones y trabajo futuro.....	39
Anexo A. Librería de sistemas de recomendación Apache Mahout - Taste.....	45
Anexo B. Ejemplo de implementación de similitud entre usuarios	47

Índice de tablas

Tabla 1: Preferencias de usuario para géneros musicales según los factores de personalidad del FFM.....	19
Tabla 2: Preferencias de usuario para géneros cinematográficos según los factores de personalidad del FFM.	20
Tabla 3: Preferencias de usuario para géneros televisivos según los factores de personalidad del FFM.....	20
Tabla 4: Preferencias de usuario para géneros literarios según los factores de personalidad del FFM.....	20
Tabla 5: Preferencias de usuario en cuanto a la diversidad de características individuales.....	21
Tabla 6: Estadísticas del conjunto de datos utilizado.....	28
Tabla 7: Ejecución de recomendaciones de películas en dominio simple.....	31
Tabla 8: Ejecución de recomendaciones de música en dominio simple	31
Tabla 9: Ejecución de recomendaciones de libros en dominio simple.....	32
Tabla 10: Ejecución de recomendaciones de películas a partir de las preferencias sobre música en dominios cruzados con solapamiento (&)	32
Tabla 11: Ejecución de recomendaciones de películas a partir de las preferencias sobre libros en dominios cruzados con solapamiento (&).....	32
Tabla 12: Ejecución de recomendaciones de música a partir de las preferencias sobre películas en dominios cruzados con solapamiento (&)	33
Tabla 13: Ejecución de recomendaciones de música a partir de las preferencias sobre libros en dominios cruzados con solapamiento (&).....	33
Tabla 14: Ejecución de recomendaciones de libros a partir de las preferencias sobre películas en dominios cruzados con solapamiento (&).....	33
Tabla 15: Ejecución de recomendaciones de libros a partir de las preferencias sobre música en dominios cruzados con solapamiento (&).....	34
Tabla 16: Ejecución de recomendaciones de películas a partir de las preferencias sobre música en dominios cruzados sin solapamiento (→)	34
Tabla 17: Ejecución de recomendaciones de películas a partir de las preferencias sobre libros en dominios cruzados sin solapamiento (→)	35
Tabla 18: Ejecución de recomendaciones de música a partir de las preferencias sobre películas en dominios cruzados sin solapamiento (→)	35
Tabla 19: Ejecución de recomendaciones de música a partir de las preferencias sobre libros en dominios cruzados sin solapamiento (→)	35
Tabla 20: Ejecución de recomendaciones de libros a partir de las preferencias sobre películas en dominios cruzados sin solapamiento (→)	36

Tabla 21: Ejecución de recomendaciones de libros a partir de las preferencias sobre música en dominios cruzados sin solapamiento (→) 36

Índice de figuras

Ilustración 1: Esquema simple del funcionamiento de un Sistema de Recomendación.....	11
Ilustración 2: Esquema del proceso de generación de una recomendación [1].....	12
Ilustración 3: Esquema de un Sistema de Recomendación Basado en Contenido (CB)	13
Ilustración 4: Esquema de un Sistema de Recomendación Basado en Filtrado Colaborativo (CF).	15
Ilustración 5: Esquema de una Sistema de Recomendación Híbrido	16
Ilustración 6: Esquema de la arquitectura de Taste [33]	46

1. Introducción

1.1. Motivación

Los sistemas de recomendación (SR) son programas de ordenador que generan recomendaciones sobre un determinado objeto, a partir de las preferencias (gustos, intereses) y evaluaciones dadas por los usuarios. El uso de estos sistemas ha crecido exponencialmente debido a que son muy útiles para evaluar y filtrar la gran cantidad de información disponible en la Web, con objeto de asistir a los usuarios en sus procesos de búsqueda y recuperación de información [1].

Forman parte de un tipo específico de técnicas de filtro de información que presentan distintos tipos de ítems de información (películas, canciones, libros, noticias, imágenes, páginas web, etc.) que son del interés del usuario. Generalmente, un SR compara el perfil del usuario con algunas características de los ítems, y busca estimar el “ranking” o ponderación que el usuario le daría a un ítem que aún no conoce o no ha consumido. Estas características pueden basarse en la relación o acercamiento del usuario con dicho ítem o con su ambiente social [2].

Desde sus orígenes en los años 90, los sistemas de recomendación han sido objeto de grandes avances, y han sido integrados de forma exitosa en multitud de sitios de comercio electrónico y ocio en Internet, como Amazon¹, Netflix², Last.fm³ y YouTube⁴. Así, por ejemplo, Netflix sugiere películas y series de televisión, y Last.fm realiza recomendaciones personalizadas de artistas y composiciones musicales.

La mayoría de los servicios personalizados de acceso, recuperación y filtrado de información comercializan con la explotación de las preferencias del usuario obtenidas de forma explícita (por ejemplo, por medio de calificaciones) o implícitamente (por ejemplo, mediante la minería de clics y eventos registrados). Además de estas preferencias, los datos contextuales tales como la hora actual, la ubicación del usuario y el contexto social también son tenidos en cuenta por los servicios de personalización [3].

Los SR se han ido consolidando como potentes herramientas para ayudar a reducir la sobrecarga a la que las personas se enfrentan en los procesos de búsqueda de información. Realizan el filtrado y sugerencia de los ítems usando distintas técnicas para identificar aquellos que mejor satisfacen los gustos o necesidades de los usuarios, a partir de opiniones, búsquedas previas o su propio perfil [4].

Existen dos tipos principales de SR: Sistemas de Filtrado Colaborativos (FC) y Sistemas Basados en Contenido (CB). Los primeros tratan de explotar la inteligencia colectiva, esto es, intentan predecir la puntuación que un usuario daría a un ítem que no ha valorado aún atendiendo a las puntuaciones de ese ítem dadas por usuarios similares. Estos sistemas no necesitan ninguna información adicional sobre los ítems que recomiendan; simplemente conocen los ítems que ha valorado cada usuario y cuál ha sido la puntuación que han dado a

¹ <http://www.amazon.es/>

² <https://www.netflix.com/>

³ <http://www.lastfm.es/>

⁴ <https://www.youtube.com/>

cada uno de ellos. Un ejemplo claro es el de FilmAffinity⁵, un sitio web dedicado al cine en el que al usuario se le presentan recomendaciones sobre películas que podrían ser de su interés atendiendo a su popularidad en la comunidad de usuarios similares. En estos sistemas, el principal reto es crear para cada usuario un conjunto de “vecinos cercanos”, es decir, con gustos parecidos al usuario que se está recomendando. Por otra parte, los SR basados en contenido se basan en la similitud entre ítems prediciendo el interés que el usuario tendrá en ellos por ser muy parecidos en su contenido con otros que ya se sabe de antemano que han sido de su agrado, debido a una valoración (implícita o explícita) que el mismo usuario ha dado [5]. El servicio de alojamiento de vídeos YouTube utiliza un Sistema de Recomendación Basado en Contenido.

Si bien se ha hecho mucho esfuerzo en el estudio e investigación de los tipos de sistemas de recomendación anteriores, hasta la fecha se ha trabajado poco en la caracterización de modelos de usuario en servicios personalizados en cuanto a los rasgos afectivos, tales como el estado de ánimo, las emociones y los tipos de personalidad [6]. Las emociones son sentimientos intensos que se dirigen a alguien o algo, por ejemplo un objeto, un lugar, un suceso o un recuerdo importante. Los estados de ánimo, en cambio, son sentimientos que tienden a ser menos intensos que las emociones, y con frecuencia - aunque no siempre - necesitan de un estímulo contextual. Personalidad, por el contrario, se puede definir como una combinación de características o cualidades que conforman el estilo de una persona de pensar, sentir y comportarse en diferentes situaciones.

La personalidad influye en cómo las personas toman sus decisiones [7]. De hecho, se ha demostrado que las personas con las características de personalidad similares son propensos a tener preferencias similares [3]. Los sistemas de recomendación basados en personalidad explotan tal hecho. El sitio web de recomendaciones Blintic⁶ es un ejemplo de sistema de recomendación basado en personalidad con más de mil visitas mensuales. Inicialmente exige al usuario que conteste a un test sobre sus gustos para poder acceder al contenido de la página y así elaborar una aproximación sobre su personalidad; una vez contestado el cuestionario se le muestran automáticamente películas, fotos y vídeos adaptados a sus respuestas.

En psicología, el Modelo de los Cinco Factores (en inglés *Five Factor Model*, FFM), también conocido como Modelo de los Cinco Grandes, describe la personalidad como la composición de cinco factores generales [8]. Se trata de una teoría disposicional, que apuesta por la existencia de un conjunto de rasgos en una persona detectables mediante la observación y que permiten anticipar lo que se espera de ella. Esta teoría reúne los cinco rasgos principales y más descriptivos de una persona [9], denominados como factor OPE (*Openess* o apertura a nuevas experiencias), factor CON (*Conscientiousness* o responsabilidad), factor EXT (*Extraversion* o extraversión), factor AGR (*Agreeableness* o amabilidad) y factor NEU (*Neuroticism* o inestabilidad emocional). Al igual que las preferencias de usuario, estos factores pueden deducirse de manera explícita, por ejemplo, por medio de cuestionarios de personalidad, o implícitamente, mediante el análisis de las características lingüísticas los textos escritos por el usuario, y la correlación de los rasgos de personalidad con los patrones de uso de las redes sociales (publicaciones, clasificaciones, establecimiento de relaciones de amistad o participación en grupos de usuarios) [3].

⁵ <http://www.filmaffinity.com/es>

⁶ <http://blintic.com/>

1.2. Objetivos

El objetivo de este trabajo es explotar la correlación existente entre las preferencias de los usuarios y sus tipos de personalidad, para proponer nuevos métodos de filtrado colaborativo, que sean más eficaces para mejorar los servicios de personalización y la experiencia en cuanto a la perspectiva de la interacción persona-ordenador.

Además, en el trabajo se propone evaluar dichos métodos con métricas y metodologías comúnmente usadas en el área de los sistemas de recomendación.

1.3. Contribuciones

Las principales contribuciones de este Trabajo de Fin de Grado han sido la sencilla explotación de información de personalidad de los usuarios en técnicas clásicas de filtrado colaborativo, así como los numerosos experimentos que se han llevado a cabo utilizando distintos conjuntos de datos. Estos se han evaluado utilizando CF teniendo en cuenta la personalidad además de las preferencias de usuario, como factor determinante para el cálculo de la similitud entre usuarios.

Además, los diversos métodos de filtrado colaborativo basados en personalidad se han evaluado sobre grandes conjuntos de datos correspondientes a varios dominios de entretenimiento (música, películas y libros), y su posterior aplicación a distintos escenarios de recomendación (recomendación en dominios simples y cruzados).

1.4. Estructura del trabajo

En el capítulo 2 se describirá más detalladamente en qué consiste y cómo se logra el modelado y la adquisición de información sobre personalidad, definiendo el Modelo de los Cinco Factores como técnica principal, especificando su origen y analizando cada uno de los factores independientemente, además de otros modelos existentes.

En el capítulo 3 se realizará un estudio en profundidad de los Sistemas de Recomendación de forma general, y orientados a personalidad de forma particular. Además se analizan las correlaciones existentes entre las preferencias de usuario y los tipos de personalidad basados en los factores estudiados en el capítulo 2, sobre datos proporcionados por una aplicación de la red social Facebook⁷.

En el capítulo 4 se encuentran definidos los distintos métodos empleados para calcular la similitud entre dos usuarios teniendo en cuenta el valor de los factores FFM que componen su personalidad.

En el capítulo 5 se evaluarán los métodos de recomendación propuestos en los capítulos anteriores. Se definirán los conjuntos de datos que se han utilizado para la realización de los experimentos, las metodologías y métricas aplicadas a dichos conjuntos, y los distintos escenarios creados.

⁷ <https://www.facebook.com/>

En el capítulo 6 se encuentran los resultados obtenidos tras la realización del experimento sobre el conjunto de datos, tanto para los dominios simples como para los dominios cruzados.

Por último, en el capítulo 7 se encuentran las conclusiones a las que se ha llegado tras la realización de este proyecto además de las orientadas a un trabajo futuro para seguir investigando en el tema de la relación entre la personalidad y las preferencias de usuario.

2. Trabajo relacionado: Modelado y adquisición de información sobre la personalidad

2.1. El modelo de los Cinco Factores de personalidad

El Modelo de los Cinco Factores (FFM, del inglés *Five Factor Model*), también conocido como Modelo de los Cinco Grandes (*Big Five* en inglés) surge como un paradigma comprehensivo que ofrece un marco de referencia para la interpretación de la personalidad.

A lo largo de la historia se ha intentado entender la variabilidad de la conducta humana desde diferentes perspectivas teóricas. Sin embargo, el FFM tiene un origen basado en la experiencia, ya que su enfoque categorial del léxico surge de investigaciones empíricas vinculadas a la teoría factorial de los rasgos [10].

Sir Francis Galton fue el primer científico que reconoció la Teoría Léxica, esto es, la idea de que las diferencias en personalidad más relevantes socialmente están codificadas en el lenguaje mediante adjetivos que las designe [8]. La búsqueda de estos términos comienza con un estudio de Gordon Allport y H. S. Odbert en 1936, quienes listaron 17.953 palabras que reflejaban las características de la personalidad en la edición de 1925 del *Webster's New International Dictionary* (4,5% del total de palabras del diccionario) [11]. Posteriormente, esa lista quedó reducida a 4.504 adjetivos que describían rasgos observables y relativamente permanentes.

La clasificación en categorías de esos adjetivos fue la siguiente [11]:

- i. Términos neutrales que designan rasgos personales (por ejemplo, "artístico", "asertivo").
- ii. Términos principalmente descriptivos de las actividades o estados de ánimo temporales (por ejemplo, "alarmado", "avergonzado").
- iii. Términos ponderados que transmiten juicios sociales o de carácter de la conducta personal, o que designan influencia en los otros (por ejemplo, "adorable", "necio").
- iv. Misceláneos: Designaciones de físico, capacidades y condiciones de desarrollo; términos metafóricos y dudosos (por ejemplo, "solo", "anglicano").

Creían en la primera categoría como una compilación de términos no evaluativos para rasgos perdurables.

Raymond Cattell, tras una investigación psicológica en 1940, introdujo nuevos términos a la lista de Allport-Odbert y eliminó todos los sinónimos que esta contenía hasta obtener una lista actualizada con 171 palabras en total. Tras esto realizó una encuesta a cien individuos adultos que consistía en que utilizaran dicha lista para evaluar a otros individuos que ya conociesen. Al analizar los resultados, el psicólogo británico determinó la existencia de 35 variables bipolares [12], a las cuales denominó la "esfera de la personalidad" [8].

Argumentaba que en psicología se obtienen datos de diferentes formas, pero dado que ninguna es completamente satisfactoria, se deben combinar los aspectos negativos de unos con los positivos de otros. Distingue tres tipos de datos [12]:

- **Datos L** (*life* o vida) que hacen referencia a hechos contrastables de la vida real, como la edad, el nivel educativo, etc.
- **Datos Q** (*questionnaire* o cuestionarios) que son datos aportados por el individuo que está siendo evaluado, y por lo tanto puede mentir o auto-engañarse.
- **Datos T** (*objective test* o pruebas objetivas) que son pruebas en las que el individuo no tiene conciencia de la relación entre su respuesta y la característica de personalidad que se pretende medir.

Cattell y sus colaboradores realizaron otra evaluación consistente en encontrar los mismos factores obtenidos con datos L, utilizando datos Q. Para ello construyeron tests de personalidad que se administraron a grandes grupos, y cuyos resultados fueron analizados con la emergente tecnología informática combinada con el método estadístico del análisis factorial. De todo esto surgió la denominada Teoría de los Rasgos, obteniéndose 16 factores, de los cuales 12 eran comunes a ambos métodos [12].

El siguiente paso fue el desarrollo de Donald. W. Fiske en 1949. Este psicólogo estadounidense utilizó las variables bipolares de Cattell, constatando la existencia de los **Cinco Factores**.

En 1961 dos investigadores de las Fuerzas Aéreas de Estados Unidos, Tupes y Christal, mantuvieron una línea similar al utilizar los datos procedentes de los trabajos de Cattell. Recurrieron a las hetero-evaluaciones: evaluaciones de sujetos realizadas por personas afines a los mismos. Emplearon ocho muestras de sujetos distintos (1813 en total) de edades variadas y sexos en proporciones similares. Fueron analizados por observadores empleando las 35 variables de Cattell, y también encontraron que cinco los factores eran recurrentes [13].

Warren Norman en 1963 y Lew Goldberg en 1981 replicaron el estudio encontrando de nuevo los cinco factores, a los que el último denominó "*Big Five*". Norman, sin embargo, dio nombre a cada uno de ellos, siendo Extraversión, Agradabilidad, Conciencia, Estabilidad Emocional y Cultura [8].

Posteriormente, en 1985, Costa y McCrae desarrollaron un instrumento para medir los factores en base a ese modelo y comprometidos con la Teoría del Rasgo. El modelo que propusieron no es únicamente descriptivo, pues pretende justificar la naturaleza de los rasgos, y describir sus relaciones. Elaboraron un test específico, el **NEO-PI**, que adquiere su nombre de las iniciales, en inglés, de tres de los factores (*Neuroticism, Extraversion, Openness-Personality Inventory*), convirtiéndose así en los máximos representantes del modelo [13].

Los cinco factores se definen como sigue [8]:

Extraversión (EXT): (en inglés, *Extraversion*) desde solitario o reservado hasta extrovertido o enérgico. Este factor refleja la tendencia de una persona a buscar la estimulación en la compañía de otras personas (mostrando rasgos de sociabilidad, locuacidad y asertividad), y poner énfasis en la búsqueda de las emociones positivas, como la felicidad, la satisfacción y excitación. Una puntuación alta de extraversión conlleva fuertes grados de cordialidad, gregarismo, nivel de actividad, la búsqueda de sensaciones nuevas y la alegría [3].

Lo opuesto sería la Introversión. Los individuos suelen caracterizarse por ser reservados, son confundidos por antipáticos, poco dependientes de otros, prefieren lo conocido y habitual. Preferencia a estar solos antes que en situaciones sociales muy animadas. No quiere decir que

sean introspectivos e infelices. En situaciones como círculos cerrados de amigos pueden ser tan animados y habladores como los extraverteridos.

Amabilidad (AGR): (en inglés, *Agreeableness*) desde frío o cruel hasta amistoso o compasivo. Este factor refleja la tendencia de una persona a ser amable, preocupado, veraz y cooperador con los demás. Una puntuación alta de agradabilidad o amabilidad conlleva fuertes grados de moralidad, el altruismo, la solidaridad, la modestia, la confianza, la cooperación y la conciliación [3].

En su polo opuesto el individuo es egocéntrico, escéptico y competitivo. Otra definición de esta dimensión, denominada por sus autores como Complacencia amistosa versus No complacencia hostil. Su polo positivo refiere a la docilidad más la capacidad de establecer relaciones interpersonales amistosas; y su polo negativo, al establecer relaciones hostiles. Pese a que social y psicológicamente se ve más saludable el polo positivo, esto no es necesariamente así ya que la "no agradabilidad" en sus componentes de escepticismo y pensamiento crítico, es necesaria para el desarrollo de muchos ámbitos del quehacer humano, como por ejemplo en la ciencia.

Responsabilidad (CON): (en inglés, *Conscientiousness*) desde descuidado o manipulable hasta organizado o eficiente. Este factor refleja la tendencia de una persona a mostrar autodisciplina y aspirar a logros personales, y tener un comportamiento organizado (no espontáneo) y confiable. Una puntuación alta de responsabilidad implica altos grados de autoeficacia, el orden, el sentido del deber, la voluntad de logro-esfuerzo y la cautela.

Neuroticismo o Inestabilidad emocional (NEU): (en inglés, *Neurotism*) desde seguro y tranquilo hasta desconfiado y nervioso. Este factor refleja la tendencia de una persona a experimentar emociones desagradables y negativas, como la ira, la ansiedad, la depresión y la vulnerabilidad, y se refiere al grado de estabilidad emocional y control de los impulsos. Tienden a responder emocionalmente a los estímulos relativamente neutros. A menudo están de mal humor, lo que afecta en gran medida a su forma de pensar y tomar decisiones. Una alta puntuación de neuroticismo implica fuertes grados de hostilidad, ansiedad social, depresión, falta de moderación, la vulnerabilidad y la impulsividad [3].

Apertura a la experiencia (OPE): (en inglés, *Openness*) a menudo denominado simplemente como apertura, describe la distinción entre las personas creativas, imaginativas y con los pies en la tierra, de las personas convencionales. Este factor refleja la tendencia de una persona a la curiosidad intelectual, la creatividad y la preferencia por la novedad y la variedad de experiencias. Las personas con puntuaciones altas de apertura suelen ser individualistas e inconformistas, y además son muy conscientes de sus sentimientos. Esto conlleva fuertes grados de imaginación, interés artístico, emocionalidad, audacia, inteligencia y el liberalismo. El individuo abierto es original e imaginativo, curiosos por el medio externo e interno, con vidas más ricas en experiencia e interesados por ideas nuevas y valores no convencionales.

En su polo opuesto el individuo tiende a ser convencional en su conducta y apariencia, prefieren lo familiar a lo novedoso y son social y políticamente conservadores. Estas personas tienden a tener intereses comunes. Prefieren pensar simple y sencillo en lugar de complejo, ambiguo y sutil.

Aunque existe un gran consenso acerca del número de factores, éste disminuye cuando se trata del significado de cada uno de ellos. Así mismo, no es igual el factor **Cultura** de Norman, que el factor **Apertura a la experiencia** de McCrae y Costa [13].

El cuestionario “Big Five” (BFQ) es un test con 132 elementos de respuesta múltiple que miden las cinco dimensiones mencionadas, con dos sub-escalas cada una, además de una escala de distorsión con la que se evalúa la tendencia a mentir sobre uno mismo [12].

Es importante tener en cuenta que, aunque estos factores son conjuntos estadísticos, pueden existir excepciones en los perfiles individuales. En general, las personas con alto grado de OPE están dispuestas a nuevas experiencias, emocionalmente receptivos, intelectualmente curiosos e interesados por el arte. Sin embargo, un individuo en particular puede tener un alto grado de OPE, estar interesado en aprender y explorar nuevas culturas, pero no estar interesado en el arte. No obstante está demostrado que los cinco factores abarcan los rasgos de personalidad más conocidos y representan la estructura básica de todas las características de personalidad, integrando así todos los hallazgos y teorías de investigación con la psicología de la personalidad [3].

2.2. Otros modelos de personalidad

Puede ser interesante emplear otros tipos de modelos de personalidad dependiendo del dominio que represente la base del estudio realizado dentro de la comunidad de sistemas de recomendación.

Así por ejemplo existe el modelo vocacional **RIASEC** (cuyos tipos de personalidad principales son Realista, Investigador, Artístico, Social, Emprendedor y Convencional), que se utilizó en un prototipo de comercio electrónico.

Por otro lado se encuentra el modelo **Bartle** utilizado en el dominio de los videojuegos y cuyos tipos de personalidad son Asesinos, Triunfadores, Exploradores y Socializadores.

2.3. Adquisición de la personalidad

Adquisición explícita

Un cuestionario ampliamente utilizado para la evaluación de los factores del FFM, analizados en profundidad en este capítulo, es el *International Personality Item Pool* (**IPIP**, o Inventario de Personalidad). La página Web de IPIP⁸ contiene cuestionarios con 50 y 100 elementos, dependiendo del número de preguntas por factor (10 o 20). El número relativamente elevado de preguntas hace que sea un instrumento preciso, aunque conlleva un elevado gasto de tiempo para los usuarios que lo realizan. Por otra parte, este cuestionario se ha traducido a muchos idiomas y validado en cuanto a diferencias interculturales.

⁸ International Personality Item Pool: Inventario de personalidad. Se trata una versión posterior del test elaborado por Costa y McCrae NEO-PI, cuyos factores representativos del modelo eran NEU, EXT y OPE. (Véase el capítulo 2.1 El modelo de los Cinco Factores de personalidad de este documento). <http://ipip.ori.org/>

En el cuestionario definido por los profesores Hellriegel y Slocum en su libro *Organizational Behavior* [14], cada factor se mide a través de cinco preguntas, lo que hace un total de 25 preguntas en el cuestionario. El valor de cada factor es la media de las puntuaciones de los usuarios en cada una de sus cinco preguntas. Estos están obligados a contestar todas las preguntas utilizando un rango de 1 a 5, siendo 1 la puntuación más baja y 5 la más alta.

Los profesores de la Universidad de California John y Srivastava desarrollaron una lista más exhaustiva que contiene 44 elementos, llamada *Big Five Inventory (BFI)*, por el cual cada factor de personalidad se mide con ocho o nueve preguntas. Cada usuario responde de nuevo en una escala de 5 puntos, siendo 1 “muy en desacuerdo” y 5 “totalmente de acuerdo”, respecto a la cuestión general “me veo como alguien que...” [15]. Este cuestionario ha sido reconocido como una medida bien establecida de los rasgos de personalidad.

El cuestionario *Ten Item Personality Inventory (TIPI)* es una brevísima medida del FFM, en el que cada factor se evalúa únicamente con dos preguntas utilizando la misma escala que en el caso del BFI.

Por otro lado, **NEO PI-R** es un cuestionario controlado comercialmente cuyo inventario cuenta con 240 elementos, y además de medir los cinco factores también mide los seis subfactores de cada uno de ellos. Así por ejemplo, el factor "extroversión" (EXT) contiene seis facetas: gregarismo, asertividad, actividad, emociones positivas, entusiasmo de búsqueda y calidez. La versión truncada de este cuestionario es el NEO-FFI, que únicamente mide los cinco factores.

El empleo de cada uno de estos instrumentos que se han desarrollado hasta la fecha depende de cada aplicación, y no existe uno estándar para todas.

Algunos ejemplos de la adquisición explícita de datos son [16]:

- Solicitar al usuario que pondere, en base a una escala proporcionada, algún tema específico.
- Solicitar al usuario que pondere un conjunto de temas de una lista de temas favoritos.
- Solicitar al usuario que elija de entre dos temas expuestos únicamente uno de ellos.
- Solicitar al usuario que elabore una lista con sus temas preferidos.

Adquisición implícita

Con el desarrollo de las redes sociales, algunos investigadores han comenzado a estudiar la correlación existente entre la personalidad de los usuarios y su comportamiento social en la Web (por ejemplo, en Facebook o Twitter⁹).

Uno de estos estudios es el llevado a cabo por Sinan Aral y Dylan Walker, profesores en la New York University Stern School of Business, donde encontraron una fuerte relación entre la personalidad de los usuarios y su uso de Facebook a través de una encuesta a 237 estudiantes. La personalidad de los participantes fue evaluada mediante cuestionario NEO PI-R y los datos recogidos se utilizaron para calcular la correlación con la información del resto de usuarios de

⁹ <https://twitter.com/>

Facebook (información básica, información personal, información de contacto, educación, y trabajo).

Los resultados mostraron que los factores EXT y CON están positivamente relacionados con el número de amigos. Además, los individuos con alto grado de NEU son más proclives a publicar su información privada (como fotografías). Por último, en el factor OPE se encontró una correlación positiva en la disposición de los usuarios a utilizar Facebook como una herramienta de comunicación [17].

Algunos ejemplos de la adquisición implícita de datos son [16]:

- Guardar en un registro los dominios que el usuario ha consultado en una tienda online.
- Contabilizar y analizar el número de visitas que recibe un determinado ítem.
- Guardar en un registro los ítems que el usuario ha seleccionado.
- Obtener un listado con los ítems que el usuario ha seleccionado o visto en su ordenador.
- Analizar las redes sociales de las que el usuario forma parte para conocer sus gustos y preferencias.

3. Trabajo relacionado: Recomendación basada en personalidad

3.1. Sistemas de recomendación

Un Sistema de Recomendación (SR) es un *sistema inteligente* que proporciona al usuario una serie de sugerencias personalizadas, **recomendaciones**, acerca de ítems en uno o varios dominios dados. Los SR usan las características y preferencias de cada usuario para encontrar un subconjunto de ítems $I = \{i_1, i_2, \dots, i_N\}$ que le podrían ser de interés [1] [18].

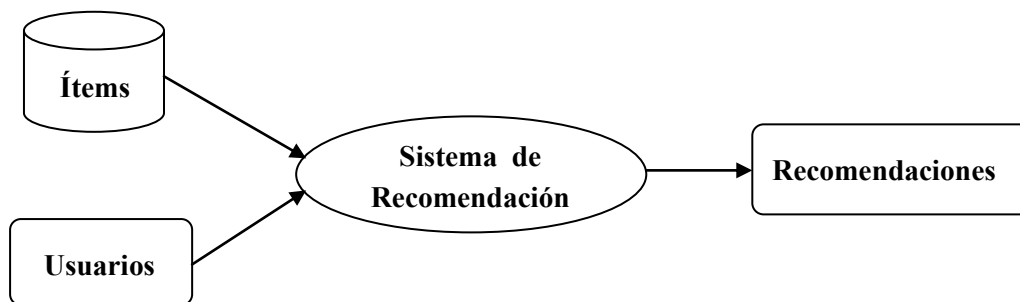


Ilustración 1: Esquema simple del funcionamiento de un Sistema de Recomendación.

La implementación de las técnicas usadas para el desarrollo de los SR está relacionada con el tipo de información que se vaya a utilizar. En primer lugar, se debe de tener en cuenta el tipo de ítem que se va a recomendar. En algunas ocasiones los SR únicamente conocerán el identificador de cada ítem (por ejemplo, el título de la película), sin embargo, en otras ocasiones se dispondrá de más información a través de una serie de atributos (por ejemplo, el género, el año en que se rodó, el director, etc.) [1].

Los elementos fundamentales que intervienen en el funcionamiento de un SR son:

- **Entradas y salidas:** Además de utilizar la información del usuario activo también es necesaria la información sobre los ítems o sobre el resto de usuarios del sistema (**vecinos** o **colaboradores**). En este último caso, la realimentación por parte de los usuarios es muy importante para poder generar recomendaciones completas y actualizadas. Las salidas del SR están constituidas por las recomendaciones generadas que varían dependiendo del tipo, la cantidad y el formato de la información proporcionada por el usuario.
- **Método de generación de recomendaciones:** Dependiendo del tipo de SR que se utilice (basado en contenido, filtrado colaborativo, híbrido).
- **Grado de personalización:** Utilizado también para clasificar los SR. Si las recomendaciones proporcionadas son las mismas para todos los usuarios se trata de un SR no personalizado, basándose en selecciones manuales (clics) o datos estadísticos. Si por otro lado el SR tiene en cuenta la información actual del usuario al cual se le va a generar una o varias recomendaciones, la personalización es efímera, ya que las recomendaciones dependen del comportamiento de dicho usuario en la sesión actual de navegación. Por último, los SR cuyas recomendaciones se basan en el perfil de los

usuarios, y son distintas para cada uno de ellos (CF), se dice que utilizan personalización persistente y ofrecen mayor grado de personalización.

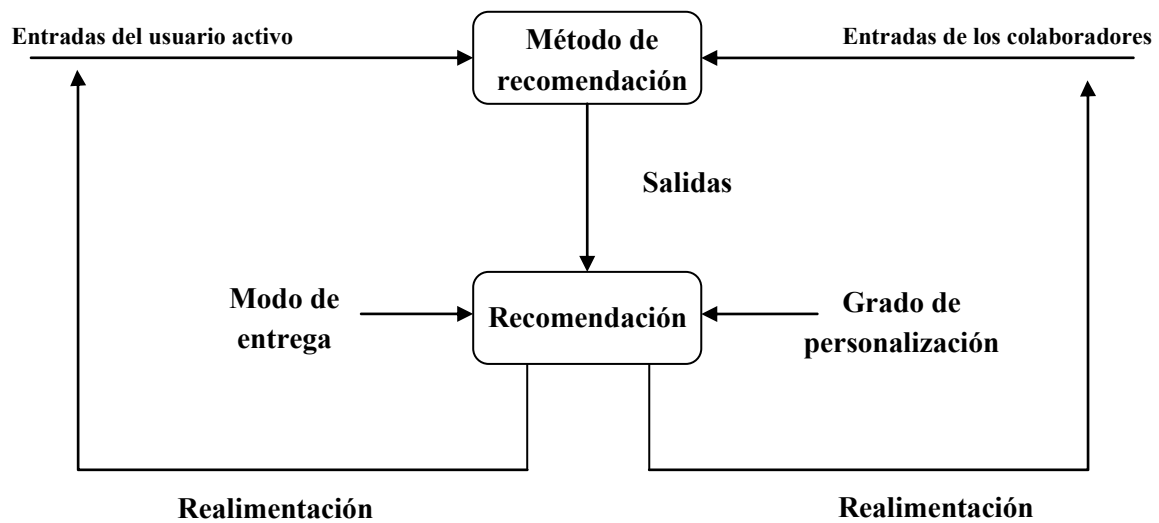


Ilustración 2: Esquema del proceso de generación de una recomendación [1].

Un problema que surge en los sistemas de recomendación es el conocido como **problema del usuario nuevo o arranque en frío**. Este problema se produce cuando el SR no tiene suficientes valoraciones de un usuario que acaba de comenzar a utilizarlo, dándose tanto en los SR basados en contenido como en los SR colaborativos donde es más difícil de resolver [19].

En primer lugar, el sistema debe tener alguna información sobre el usuario, normalmente en forma de notas. En el caso de los SR basados en contenido, la falta de calificaciones implica que, para el usuario observado, se desconocen las preferencias hacia las características de los ítems. En el caso de filtrado colaborativo, la falta de calificaciones para un nuevo usuario implica que no hay suficientes valoraciones que coincidan con las de otros usuarios, lo que hace difícil calcular las similitudes. Hasta ahora se ha venido sufragando con métodos híbridos, técnicas de aprendizaje adaptativo o simplemente recomendando ítems populares.

Además de este problema, existen otros inconvenientes que se habrán de tener en cuenta a la hora del diseño de un SR [1]:

- Baja disposición de los usuarios a proporcionar información personal sobre sus preferencias. En algunas ocasiones es necesario recurrir a incentivos que fuercen al usuario a introducir sus preferencias a cambio de recomendaciones.
- Los propietarios de determinados ítems podrían generar recomendaciones positivas de los mismos y negativos de otros. Se debe de tener en cuenta aspectos de la privacidad del usuario.
- El mantenimiento de un SR es costoso.
- Mejorar las técnicas de representación de las preferencias o recomendaciones de los usuarios para una mejor captación sobre su percepción y valoración del ítem e incrementar la relación SR-usuario.

Sistemas de Recomendación Basados en contenido (CB)

Los SR basados en contenido (en inglés *content-based recommender systems*) buscan utilizar la información disponible tanto del ítem como del usuario para calcular la recomendación más adecuada [20]. Estos SR tratan de sugerir al usuario ítems que son similares a los que se sabe que le gustaron en un pasado, o que actualmente está examinando. En general, el CB recomienda ítems a usuarios si la **información asociada a los ítems** concuerda con las **preferencias de los usuarios**. Una preferencia representa una relación entre un determinado usuario y los datos, y más concretamente entre un usuario y un atributo asociado a los datos. Las preferencias de los usuarios pueden representarse de las siguientes maneras [21]:

- Mediante un **perfil del usuario**, que recopila las preferencias del usuario a través de su actividad previa o su opinión, recogida en un cuestionario.
- Mediante un **modelo del usuario** que modela la información almacenada en su perfil, para extraer algún tipo de conocimiento de esta información que defina mejor las preferencias del usuario.

Este enfoque tiene sus raíces en la recuperación y el filtrado de información. Estos métodos utilizan el perfil de un ítem, es decir, un conjunto de atributos que caracterizan al ítem. El sistema CB genera un perfil del usuario basado en un vector ponderado con los atributos de los ítems preferidos. Los pesos denotan la importancia que tiene cada característica para el usuario y pueden ser calculados a partir de vectores de contenido valorado individualmente usando diversas técnicas. Los métodos simples utilizan los valores medios del vector, mientras que otros utilizan técnicas de aprendizaje automático como los clasificadores bayesianos, que clasifican los ítems en relevantes y no relevantes, árboles de decisión y redes neuronales para estimar la probabilidad de que a un determinado usuario le guste un determinado ítem.




Ilustración 3: Esquema de un Sistema de Recomendación Basado en Contenido (CB)

En algunos sitios de comercio electrónico y redes sociales existe la posibilidad de que un usuario indique su agrado o desagrado, normalmente a través de un botón, con algún ítem (por ejemplo, el botón “Like” o “Me Gusta” de Facebook). Estas valoraciones pueden utilizarse para indicar un mayor o menor peso (interés) sobre determinados atributos de ítem.

Una cuestión clave del filtrado basado en contenido es si el sistema es capaz de aprender las preferencias del usuario a partir de sus acciones dentro de un dominio (p.e. música) y utilizarlas en otros (p.e. cine). Cuando el SR se limita a recomendar únicamente ítems pertenecientes al mismo dominio, su valor es menor que si es capaz de hacerlo con **dominios cruzados**.

Un ejemplo de ese tipo de sistema de recomendación es el sitio web Radio Pandora¹⁰ que reproduce música con características similares a las de una canción elegida por el usuario (semilla) [16].

Algunas de las ventajas que tienen los CB son [22]:

- Las recomendaciones sólo dependen de los gustos del usuario que se encuentra navegando por el sistema.
- Facilidad para explicar las recomendaciones.
- Pueden recomendarse ítems que no han sido valorados previamente por el usuario.

Por otro lado, las desventajas son:

- Limitación por el análisis de contenido (las características representan a los ítems).
- El sistema recomienda ítems parecidos a los que le gustan al usuario (sin la capacidad de sorprenderle).
- Nuevos usuarios (arranque en frío). Si un usuario ha puntuado pocos o ningún ítem, el sistema no generará buenas recomendaciones.

Sistemas de Recomendación Basados en Filtrado Colaborativo (CF)

El filtrado colaborativo (en inglés *collaborative-filtering*) es una técnica empleada por los Sistemas de Recomendación que utiliza la información de preferencias y calificación de un grupo de usuarios (“vecindario”) respecto a los ítems de un repositorio con el fin de predecir o inferir la preferencia de un usuario en particular sobre un ítem y a partir de esto generar una recomendación acertada [20].

La motivación para el filtrado colaborativo proviene de la idea de que las personas a menudo obtienen la mejor recomendación de alguien con un gusto similar. El CF explora las técnicas para hacer coincidir a las personas con intereses similares y formular recomendaciones sobre esta base. Los algoritmos de filtrado colaborativo requieren [2]:

1. **Participación activa** de los usuarios.
2. **Representación simple** de los intereses de usuarios para el sistema.
3. **Algoritmos** que son capaces de encontrar a las personas con **intereses similares**.

El usuario expresa sus preferencias valorando ítems. Estas valoraciones pueden interpretarse como el grado de interés que el usuario muestra hacia ese ítem dentro de un dominio específico. Una vez que el sistema tiene esta evaluación, compara las valoraciones con las del resto de usuarios de sistema encontrando así aquellos que tienen gustos “similares” (**vecinos**) y generando una lista de recomendaciones compuesta por los ítems que estos vecinos han evaluado de su preferencia pero aún no habían sido evaluados por el usuario activo.

¹⁰ <http://www.pandora.com/> (no accesible desde España).




Ilustración 4: Esquema de un Sistema de Recomendación Basado en Filtrado Colaborativo (CF).

La idea principal de los CF es que los usuarios con gustos similares en el pasado también tendrán gustos similares en el futuro. Se utiliza la sabiduría de la población (vecindario) para recomendar ítems. Los datos de entrada son las puntuaciones (*ratings*) que los usuarios dan a los ítems pertenecientes a un repositorio y con ellas se genera una matriz usuario-ítem. Los datos de salida son las predicciones (numéricas) que indican cuánto le gusta o le disgusta un ítem a un usuario, además de una lista compuesta por los objetos recomendados [22].

Para agrupar los usuarios o ítems similares se tiene en cuenta bien la información **explícita** que contiene la evaluación directa (comentarios, opiniones, calificaciones, etc.) que los usuarios aportan a los contenidos, o bien la información **implícita** que se extrae de evaluaciones indirectas del contenido mediante su uso (navegación, descargas, compras, etc.) [21].

Existen tres tipos de CF:

- **Basado en usuarios:** Los usuarios se agrupan según hayan designado relevantes o no al mismo conjunto de ítems. Como ya se ha dicho, es lógico pensar que usuarios que han compartido gustos e intereses en un pasado lo hagan de nuevo en un futuro y, por tanto, si un usuario considera relevante un ítem nuevo, éste será recomendado a todos sus vecinos. Este es un método **basado en memoria** y su complejidad es $O(N^2 \times M \times K)$, donde N es el número de usuarios, M el número de ítems y K el número de vecinos.

A la hora de desarrollar este tipo de sistemas es necesario establecer por un lado el tamaño K del “*neighbourhood*” o “vecindario” y por otro una medida de similitud para comparar usuarios [21]. El algoritmo basado en la vecindad calcula la similitud entre dos usuarios o elementos, produce una predicción para el usuario tomando el promedio ponderado de todas las evaluaciones. Calcular la similitud entre los elementos o usuarios es una parte importante de este enfoque. Múltiples mecanismos tales como la **correlación de Pearson** y la **similitud basada en el coseno** entre vectores, explicadas ambas en detalle en el siguiente capítulo, sirven para esto.

- **Basado en ítems:** En este caso se agrupan los ítems en lugar de los usuarios. Si un grupo de ítems ha sido considerado relevante para un usuario, un ítem similar al conjunto es probable que sea también relevante para este usuario. El proceso de recomendación de un ítem consiste en la predicción de la puntuación que el usuario daría a ese ítem según la puntuación que ya ha dado a otros ítems similares. Este método fue inventado por Amazon (usuarios que compraron X, también han comprado Y) y su complejidad es similar al caso anterior $O(M^2 \times N \times K)$.
- **Basado en modelos:** Este método se basa en la aplicación de técnicas de **clustering** para agrupar tanto los usuarios como los ítems que sean similares. El clustering de usuarios se lleva a cabo para agrupar a los que tienen preferencias similares y, en el caso de los ítems, se agrupan los que tienen contenidos similares; así las recomendaciones que se generarán tendrán en cuenta únicamente los contenidos que se encuentren en el mismo clúster. Otros tipos de modelos son los bayesianos o los modelos basados en reglas de asociación.

Las desventajas de este método son el coste de la construcción del modelo y la posible pérdida de información debido a la reducción del mismo. La complejidad de este tipo de sistemas es menos costosa que las anteriores $O(N \times M \times K \times L)$.

Los problemas asociados a los CF son:

- Complejidad.
- Arranque en frío (en inglés cold start).
- Escasez de datos.
- Falta de diversidad.

Sistemas de Recomendación Híbridos

Los sistemas híbridos combinan las técnicas de CB y CF con el fin de mejorar las recomendaciones resultantes o superar problemas como el arranque en frío que presentan algunos de los métodos anteriores al ser utilizados por separado.

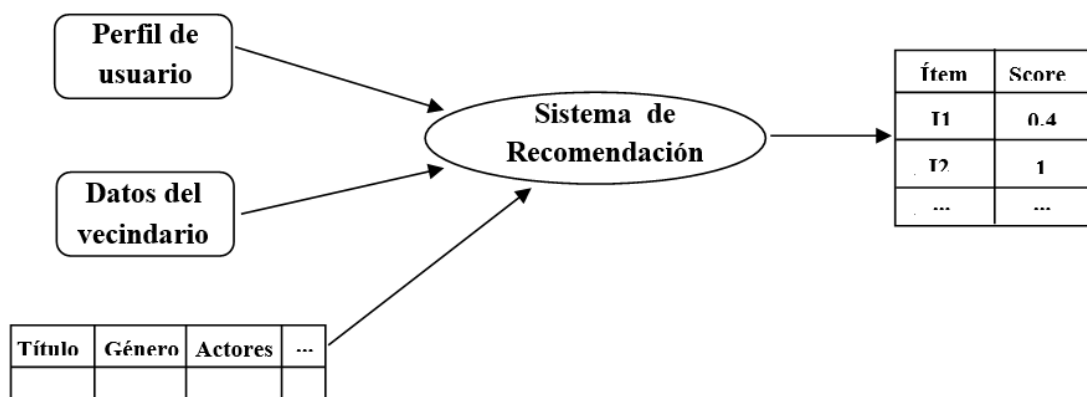


Ilustración 5: Esquema de una Sistema de Recomendación Híbrido

La creación del perfil puede realizarse por un método de ponderación manual en el que cada usuario da un peso a los atributos de los ítems de acuerdo a sus gustos o puede ser automática donde la ponderación se calcula usando características de los atributos e información previa del usuario. Los perfiles son agrupados mediante algoritmos de clústering para proveer la información con contenido semántico. Estos clústers son tratados como ítems para formar una nueva matriz usuario-ítem, y la similitud entre los usuarios de esta nueva matriz se obtiene con una combinación de los coeficientes de correlación calculados por el método del coseno y de Pearson. Finalmente predicciones para los nuevos usuarios se realizan aplicando sobre la nueva matriz creada un algoritmo de filtrado colaborativo [20].

3.2. Sistemas de recomendación sobre dominios cruzados

Debido al gran crecimiento de los sitios que se dedican al comercio electrónico y de la expansión que tienen a día de hoy las distintas redes sociales, los usuarios crean perfiles en internet donde dan su opinión aportando información acerca de sus gustos e intereses. Estos perfiles son de gran utilidad para evitar el principal problema del arranque en frío que sufren los sistemas de recomendación; los datos sobre las preferencias del usuario son utilizados para la generación de modelos y mejores recomendaciones. Gracias a este tipo de perfiles se solventa la escasez de información acerca de un dominio de destino y se establecen las recomendaciones de venta cruzada de productos de distintos dominios.

Así, se pueden definir los sistemas de recomendación sobre dominios cruzados como sistemas de recomendación que ayudan a generar o a mejorar las recomendaciones personalizadas en un dominio de destino mediante el análisis de los datos conocidos en otro dominio que se considera de origen, en este caso, correspondientes con las preferencias de usuario.

A través de estrategias de agregación de preferencias de usuario y de mediación, este modelo ha sido empleado como posible solución para mitigar los problemas de arranque en frío y escasez de información en los sistemas de recomendación.

Se pueden distinguir dos tipos principales de enfoque de los dominios cruzados:

- I. Utilizar información procedente de varios dominios de origen para realizar recomendaciones en un dominio de destino (por ejemplo, utilizar los datos acerca de las preferencias sobre música de un usuario para hacerle recomendaciones sobre cine).
- II. Vincular o transferir conocimientos entre varios dominios de origen para apoyar las recomendaciones en un dominio de destino.

Los métodos de agregación de conocimiento mezclan las preferencias de usuario (estas son, valoraciones, etiquetas sociales y conceptos semánticos), modelan los datos que serán explotados por diversos sistemas de recomendación (por ejemplo, similitudes entre usuarios y los usuarios de un barrio), y combinan las recomendaciones de un dominio en particular (por ejemplos, las estimaciones de clasificación y las distribuciones de probabilidad de clasificación).

Los métodos de vinculación y transferencia de conocimientos pueden relacionar dominios por un conocimiento común (por ejemplo, propiedades de un elemento, reglas de asociación y correlaciones entre dominio), compartir características implícitas ocultas que relacionen

dominios de origen y de destino, y aprovechar los patrones de clasificación explícitos e implícitos del dominio de origen en el dominio de destino [23].

También podemos pensar en otros campos que no tengan que ver con los dominios que se han explotado en este trabajo (música, cine y literatura) como objeto de comercio, por ejemplo, en una aplicación turística podría resultar valioso sugerir un evento cultural a un usuario que ha hecho la reserva de una habitación en un hotel recomendado, o en un sistema de *e-learning*, sugerir a un estudiante referencias bibliográficas relacionadas con una video-lección que se le ha recomendado recientemente [24].

3.3. Relaciones entre preferencias y personalidad del usuario

Correlaciones entre preferencias de usuario y tipos de personalidad

A cualquier momento del día en los hogares, oficinas, coches, restaurantes y clubes de todo el mundo, la gente está escuchando música. A pesar de su prevalencia en la vida cotidiana, sin embargo, el sonido de la música se ha mantenido en silencio dentro de la psicología social y de la personalidad. De hecho, de los cerca de 11.000 artículos publicados entre 1965 y 2002 en las principales revistas sociales y de personalidad, la música fue incluida en el índice o algún título en únicamente siete de ellos. El psicólogo experto en personalidad Raymond Cattell incluso comentó la desconcertante ausencia de la investigación sobre la música: *“Tan poderoso es el efecto de la música... que uno se sorprende de encontrar en la historia de la psicología y la psicoterapia tan pocos experimentos, o incluso especulaciones, referentes al uso de la música”*.

La música es un fenómeno social en todas partes. Es el centro de muchas actividades sociales, como conciertos, donde la gente se reúne para escuchar música y hablar de ella. Incluso en las reuniones sociales donde la música no es el objetivo principal, sí que es un componente esencial (sólo hay que imaginarse una boda o unas fiesta sin música).

La música también puede satisfacer una serie de necesidades más allá del contexto social. Así como las personas dan forma a sus entornos sociales y físicos para reforzar sus disposiciones e imagen, la música que elija puede tener una función similar. Por ejemplo, un individuo con un alto de **OPE** puede preferir estilos de música que refuercen su carácter artístico y sofisticado.

Por otra parte, las personas pueden buscar determinados estilos de música para regular sus estados de ánimo y emociones, por ejemplo, las personas con depresión pueden optar por estilos de música que mantienen su estado de ánimo melancólico [25].

Los psicólogos Peter J. Rentfrow y Samuel D. Gosling, de la Universidad de Texas han demostrado científicamente que las preferencias musicales de cada individuo definen su personalidad. Hace unos años idearon el "Test Corto de las Preferencias Musicales" (Short Test Of Music Preferences, STOMP) y sometieron a varios centenares de jóvenes a sus preguntas. Se han realizado varios estudios obteniendo resultados similares [3] para distintos **géneros musicales**:

Factor (FFM)	HIGH SCORES	LOW SCORES
<i>OPE</i>	Blues, clásica, indie	R&B, rap, hip hop
<i>CON</i>	Country, jazz, salsa, R&B	Indie, metal, techno, rap
<i>EXT</i>	Salsa, hip hop, rap	Metal, techno, rock
<i>AGR</i>	Country, clásica, dance, jazz	Metal, rap, indie
<i>NEU</i>	Indie, metal, rock	Salsa, jazz, hip hop

Tabla 1: Preferencias de usuario para géneros musicales según los factores de personalidad del FFM.

myPersonality¹¹ es una aplicación de Facebook¹² con la que los usuarios realizan pruebas psicométricas reales. A partir de abril de 2013, la herramienta ha permitido registrar una base de datos que contiene más de 6 millones de resultados de las pruebas y más de 4 millones de perfiles individuales de Facebook con una gran variedad de información personal del usuario, como datos demográficos y de geo-localización, gustos, actualizaciones de estado, y las relaciones de amistad, entre otros.

Para obtener resultados del resto de dominios que se van a investigar en este trabajo (películas, música y libros), observamos que Cantador, Fernández-Tobías y Bellogín en su artículo *Relating Personality Types with User Preferences in Multiple Entertainment Domains* [3] analizan los datos que el equipo de myPersonality ha puesto a disposición del público. En concreto, el conjunto de datos público contiene las puntuaciones de personalidad del FFM de 3,1 millones de usuarios, usando del 20 al 336PF IPIP proporcionados por los cuestionarios de Costa y McCrae, de los cuales alrededor del 40% de los usuarios tuvo la versión 100PF13. También contiene 46 millones de "likes" de 220.000 usuarios de 5,5 millones de elementos de distinta naturaleza: personas (celebridades, políticos, directores, actores, músicos, escritores, deportistas, etc.), objetos (películas, programas de televisión, canciones, libros, juegos, etc.), organizaciones, eventos, etc. En dicho artículo se seleccionaron todos los datos correspondientes con géneros cinematográficos, géneros televisivos, géneros musicales y géneros literarios, eligiendo de cada uno de ellos los 16 mejores.

A continuación se muestran las conclusiones a las que llegaron tras dicho estudio omitiendo los resultados correspondientes a los géneros musicales ya que se han analizado al comienzo de esta sección.

¹¹ myPersonality project, <http://mypersonality.org/>

¹² <https://www.facebook.com/>

¹³ Modelo en el que se analizan 100 factores de personalidad.

Según los géneros cinematográficos:

Factor (FFM)	HIGH SCORES	LOW SCORES
<i>OPE</i>	Neo-noir, independiente, culto, extranjeras	Bélicas, romance, acción, comedia
<i>CON</i>	Aventuras, ciencia-ficción, independiente	Culto, animación, dibujos animados
<i>EXT</i>	Drama, romance, comedia, acción	Animación, tragedia, neo-noir, ciencia-ficción
<i>AGR</i>	Aventuras, romance, comedia, drama	Comedia, animación, neo-noir, culto, terror
<i>NEU</i>	Culto, tragedia, animación	Aventuras, independientes, bélicas

Tabla 2: Preferencias de usuario para géneros cinematográficos según los factores de personalidad del FFM.

Según los géneros televisivos:

Factor (FFM)	HIGH SCORES	LOW SCORES
<i>OPE</i>	Supervivencia, documentales, monólogos	Telenovelas, juego, deportes
<i>CON</i>	Supervivencia, tertulias/debates, deportes	Dibujos animados y animación
<i>EXT</i>	Deportes, reality-shows	Dibujos animados y animación
<i>AGR</i>	Juego, tertulias/debates	Supervivencia, bromas
<i>NEU</i>	Dibujos animados, videos musicales, telenovelas	Deportes, bromas, supervivencia

Tabla 3: Preferencias de usuario para géneros televisivos según los factores de personalidad del FFM.

Según los géneros literarios:

Factor (FFM)	HIGH SCORES	LOW SCORES
<i>OPE</i>	Poesía, ciencia-ficción	Drama, terror, criminalidad
<i>CON</i>	Educativos	Cómic, fantasía, poesía
<i>EXT</i>	Terror, humor	Cómic, ciencia-ficción, guerra
<i>AGR</i>	Educativos	Guerra, criminalidad, cómic
<i>NEU</i>	Criminalidad, poesía	Thriller, misterio, no ficción

Tabla 4: Preferencias de usuario para géneros literarios según los factores de personalidad del FFM.

El objetivo de este trabajo es analizar los datos obtenidos de la red social Facebook, y hallar correlaciones entre las preferencias de los usuarios y los géneros anteriores para comprobar si existen similitudes entre ambos resultados y compararlos con las evaluaciones que acabamos de realizar.

Diversidad

Se ha investigado de manera reciente el impacto de la personalidad en las preferencias de usuario a través de la **diversidad** de recomendación. La diversidad se refiere a recomendar a los usuarios un conjunto diverso de elementos, a fin de permitirles descubrir elementos inesperados más eficazmente [26]. Los enfoques existentes adoptan normalmente una estrategia fija para ajustar el grado de diversidad dentro del conjunto de recomendaciones, que sin embargo, no considera que los diferentes usuarios pueden tener diferentes actitudes hacia los diversos elementos.

Cheng, Wen y Liang investigaron en [19] cómo la personalidad podría afectar las necesidades de los usuarios en la diversidad en los sistemas de recomendación. Llevaron a cabo una encuesta entre 181 usuarios para obtener su selección de películas, además de algunos valores de personalidad. Se consideraron dos niveles de diversidad: la diversidad en el respeto de las características individuales (género, director, actores) y la diversidad en general cuando se combinan todos los atributos. El análisis de correlación mostró que algunos factores de la personalidad tienen una influencia significativa sobre la diversidad de preferencias de los usuarios:

Factor (FFM)	VALORES ALTOS	VALORES BAJOS
<i>OPE</i>	Actor/actriz	No hay datos
<i>CON</i>	Fecha de lanzamiento	No hay datos
<i>EXT</i>	No hay datos	No hay datos
<i>AGR</i>	No hay datos	País
<i>NEU</i>	Director	No hay datos

Tabla 5: Preferencias de usuario en cuanto a la diversidad de características individuales

En cuanto a la diversidad general se obtuvo como resultado que aquellas personas con un bajo grado de CON, personas con menos conciencia, se correlacionaban de forma negativa con ella, sin importar la variedad de atributos, prefiriendo así un mayor nivel de este tipo de diversidad.

Tras estos resultados, desarrollaron una diversidad basada en la personalidad ajustando el enfoque de recomendación de películas. Incorporaron la personalidad como un factor de moderación en un SR basado en contenido. Teniendo en cuenta los valores de los factores del FFM identificaron en primer lugar qué tipo de diversidad necesitaba cada usuario. Por ejemplo, para los usuarios con un alto valor de OPE el sistema devolverá películas con diferentes actores y actrices, y el número de elementos mostrados está ajustado a la diversidad que el usuario necesita. Este método fue probado con 52 participantes comparando una variante que incorpora la personalidad de contraria, es decir, ofreciendo menos diversidad de artículos para el usuario aunque requiera un mayor nivel de diversidad dado sus valores para los factores FFM. Los usuarios quedaron más satisfechos con la recomendación basada en la personalidad, consolidando los resultados de la encuesta anterior.

El tema de este trabajo consiste en señalar la **correlación** que existe entre la personalidad del usuario y los distintos géneros de dominios de entretenimiento como son la música, las películas, y los libros.

Antes de desarrollar sistemas de recomendación basados en personalidad es importante establecer y comprender las relaciones que existen entre los tipos de personalidad y las preferencias de usuario en varios ámbitos de entretenimiento como son la música, el cine, y la literatura.

3.4. Sistemas de recomendación basados en personalidad

En el mundo real las personas están rodeadas de otras personas casi todo el tiempo, por lo tanto casi siempre hay una posibilidad potencial de pedir ayuda. Cuando se trata de la Web el proceso es imitado por los sistemas de recomendación [27]. Estos tratan de ser una alternativa al proceso social de recomendación: el acto habitual de pedir a conocidos o expertos su opinión para tomar una decisión sin necesidad de tener la suficiente información para ello. Generalmente son decisiones sencillas como qué libro leer, qué música escuchar, qué película/serie ver o qué lugares visitar [28].

En los últimos veinte años se ha producido un crecimiento exponencial del número de usuarios que eligen los sitios web de comercio electrónico como vía para comprar productos y servicios. Esto ha causado un interés especial en la comunidad científica con el objetivo de mejorar la experiencia del cliente. Los SR basados en personalidad están diseñados para proporcionar servicios personalizados, basándose en las relaciones entre las personalidades de los usuarios y sus intereses o comportamientos [29]. Estos SR entienden a los clientes desde un punto de vista psicológico.

Hasta la fecha se ha trabajado poco en la investigación en el campo de los perfiles psicológicos del usuario dentro de los SR. Las investigaciones que se han llevado a cabo han demostrado que la personalidad es un factor perdurable y primario que determina las conductas humanas, y establece una conexión con los gustos e intereses del usuario. Los estudios existentes han demostrado que estos SR basados en personalidad podrían ser más eficaces que hasta los ahora utilizados basados en calificaciones, aplicándose a una gama más amplia de aplicaciones.

Mientras que las técnicas de adquisición de información explícitas proporcionan evaluaciones precisas de las personalidades de los usuarios, son intrusivas y consumen mucho tiempo. Por lo tanto, estas técnicas son útiles sólo en estudios de laboratorio y en la evaluación de los datos en el campo de la verdad, para su extracción automática después. Por otro lado, las técnicas implícitas, ofrecen una manera discreta de la adquisición de los parámetros de personalidad. Sin embargo, la exactitud de estas técnicas no es muy alta y depende en gran medida de la calidad de la información de origen.

Otro posible problema que podría darse se debe al desconocimiento del grado de aceptación que los usuarios podrían mostrar por esta nueva tecnología, y qué aspectos de diseño y algoritmia influirían más en ello. Los principales problemas surgirían con aquellos SR basados en un cuestionario de personalidad. Se debe partir del hecho de que la percepción de utilidad y facilidad de uso son factores importantes que afectarán a la aceptación de esta nueva tecnología por parte del usuario. También se deberán seguir algunas directrices acerca del diseño, sin embargo las principales innovaciones a las que hay que prestar especial atención son los procesos que obtienen la información sobre las preferencias, y las aproximaciones de recomendación [30].

4. Métodos de recomendación basados en personalidad propuestos

4.1. Filtrado colaborativo basado en personalidad

En la bibliografía de sistemas de recomendación es habitual definir la preferencia de un usuario $u \in \mathcal{U}$ por un determinado ítem $i \in \mathcal{I}$ como un rating $r_{u,i} \in \mathcal{R}$, donde \mathcal{R} es un conjunto totalmente ordenado (por ejemplo, enteros no negativos o reales dentro de un cierto rango). Para cada usuario u el SR tiene como objetivo predecir ratings $r_{u,i}$ de ítems i no evaluados aún por u , y recomendar aquellos cuyos valores estimados $\tilde{r}_{u,i}$ sean más altos.

En particular, las estrategias de CF basado en heurísticas calculan $\tilde{r}_{u,i}$ como una agregación de ratings de algunos usuarios v , normalmente los más similares a u . Más formalmente, $\tilde{r}_{u,i} = \text{aggr}_{v \in \mathcal{N}_u} r_{v,i}$, donde \mathcal{N}_u se corresponde con un conjunto de N usuarios que son los más similares a u , llamados "vecinos". Aunque existen numerosas funciones de agregación, para este trabajo se ha escogido una de las más empleadas:

$$\tilde{r}_{u,i} = \bar{r}_u + \kappa \sum_{v \in \mathcal{N}_u} \text{sim}(u, v) \cdot (r_{v,i} - \bar{r}_v) \quad (1)$$

Fórmula 1: Función de estimación de ratings en CF

donde $\text{sim}(u, v)$ es una función que mide la similitud entre dos usuarios u y v , \bar{r}_u es la media aritmética de los ratings de los usuarios u y κ es un factor de normalización cuyo valor suele ser normalmente $\mathcal{K} = 1/\sum_{v \in \mathcal{N}_u} \text{sim}(u, v)$.

Además de la función de agregación anterior, la función de similitud entre usuarios es una componente central dentro del CF. Una métrica estándar de la similitud es la basada en el **coeficiente de correlación de Pearson (PEA)**:

$$\text{sim}(u, v) = \frac{\sum_{i \in \mathcal{I}_u \cap \mathcal{I}_v} (r_{u,i} - \bar{r}_u)(r_{v,i} - \bar{r}_v)}{\sqrt{\sum_{i \in \mathcal{I}_u \cap \mathcal{I}_v} (r_{u,i} - \bar{r}_u)^2 \sum_{i \in \mathcal{I}_u \cap \mathcal{I}_v} (r_{v,i} - \bar{r}_v)^2}} \quad (2)$$

Fórmula 2: Coeficiente de correlación de Pearson (PEA)

donde $\mathcal{I}_u \subseteq \mathcal{I}$ es un conjunto de ítems evaluados por el usuario u . Esta métrica no es aplicable a los "Me Gusta" o "Likes" de Facebook por ser valores unarios, ni tampoco a los "pulgares arriba/abajo" o "thumbs up/down" de YouTube por ser valores binarios. Para estos casos se utiliza la similitud de usuarios basada en el coeficiente de Jaccard:

$$\text{sim}_{\text{pref}}(u, v) = \frac{|\mathcal{I}_u \cap \mathcal{I}_v|}{|\mathcal{I}_u \cup \mathcal{I}_v|} \quad (3)$$

Fórmula 3: Coeficiente de Jaccard

Esta métrica ha sido la utilizada en los experimentos realizados en la implementación de este trabajo. Designaremos como CF a partir de ahora a la estrategia de filtrado colaborativo que utiliza la similitud entre las preferencias de usuario sim_{pref} sin tener en cuenta su personalidad.

Para poder incorporar la información sobre la personalidad del usuario se ha diseñado un SR Híbrido que combina linealmente $sim_{pref}(u, v)$ con $sim_{pers}(u, v)$, es decir, las similitudes entre las preferencias de los usuarios u y v con las similitudes entre su personalidad. La estrategia que se ha seguido es la siguiente:

$$sim(u, v) = \lambda \cdot sim_{pref}(u, v) + (1 - \lambda) \cdot sim_{pers}(u, v) \quad (4)$$

Fórmula 4: Estrategia para calcular la similitud entre usuarios teniendo en cuenta las preferencias y la personalidad de usuario.

donde $\lambda \in [0,1]$ controla la influencia que tienen las preferencias y la personalidad en el sistema de recomendación:

- $\lambda \approx 1$: Tienen mayor relevancia las preferencias de usuario.
- $\lambda \approx 0$: Tiene mayor relevancia la personalidad.

A continuación se van a mostrar varias fórmulas que calculan la similitud entre usuarios según su personalidad $sim_{pers}(u, v)$. Para todas ellas definiremos el perfil de los usuarios formado por los valores de cada factor FFM como $p_u = (p_{ope}, p_{con}, p_{ext}, p_{agr}, p_{neu})$.

4.2. Similitud de personalidad basada en coseno

La similitud basada en la personalidad según el coseno, COS, se define como sigue:

$$sim_{pers}(u, v) = \frac{\sum_k p_{u,k} \cdot p_{v,k}}{\sqrt{\sum_k p_{u,k}^2} \sqrt{\sum_k p_{v,k}^2}} \quad (5)$$

Fórmula 5: Similitud de usuarios teniendo en cuenta la personalidad basada en el coseno, COS.

Este método tendrá diferentes instanciaciones según el valor de λ , es decir, **COS- λ** con $0 < \lambda < 1$. Para $\lambda = 1$ el valor obtenido se corresponderá con el método **CF**, pues únicamente se tienen en cuenta las preferencias; en el caso de $\lambda = 0$ tenemos **COS-pers**, pues únicamente se analiza la personalidad del usuario.

4.3. Similitud de personalidad basada en Pearson

Este tipo de similitud entre usuarios se corresponde con el cálculo del coeficiente de correlación de Pearson, que mide la correlación lineal entre dos variables aleatorias cuantitativas, o lo que es lo mismo, la similitud entre dos cantidades numéricas.

La similitud entre usuarios basada en la personalidad fue investigada por Hu y Pu en [31], ya definida en este capítulo:

$$sim_{pers}(u, v) = \frac{\sum_k (p_{u,k} - \bar{p}_u) (p_{v,k} - \bar{p}_v)}{\sqrt{\sum_k (p_{u,k} - \bar{p}_u)^2 \sum_k (p_{v,k} - \bar{p}_v)^2}} \quad (6)$$

Fórmula 6: Similitud de usuarios teniendo en cuenta la personalidad basada en el coeficiente de correlación de Pearson, PEA.

Al igual que en COS, dependiendo del valor de λ evaluaremos **PEA- λ** y **PEA-pers**, con $0 < \lambda < 1$.

4.4. Similitud de personalidad basada en Spearman

El coeficiente de correlación de Spearman es utilizado en estadística para medir la correlación (asociación o interdependencia) entre dos variables continuas. Para calcular su valor se deben ordenar todos los datos y posteriormente reemplazarlos por su respectivo orden. La expresión de este coeficiente es la siguiente:

$$sim_{pers}(u, v) = \frac{\sum_k (s_{u,k} - \bar{s}_u) (s_{v,k} - \bar{s}_v)}{\sqrt{\sum_k (s_{u,k} - \bar{s}_u)^2 \sum_k (s_{v,k} - \bar{s}_v)^2}} \quad (7)$$

Fórmula 7: Similitud de usuarios teniendo en cuenta la personalidad basada en el coeficiente de correlación de Spearman, SPE.

donde $s_{u,k}$ es la posición de $p_{u,k}$ dentro del orden decreciente de los valores de los factores FFM de u . Al igual que en los casos anteriores COS y PEA, dependiendo del valor de λ evaluaremos **SPE- λ** y **SPE-pers**, con $0 < \lambda < 1$.

5. Evaluación de los métodos de recomendación propuestos

5.1. Conjunto de datos

El conjunto de datos utilizado para la evaluar los métodos de recomendación propuestos ha sido extraído de la base de datos que hizo pública la aplicación *myPersonality* en Facebook, en la que los usuarios realizan pruebas psicométricas reales. A partir de abril de 2013, la herramienta ha permitido registrar una base de datos que contiene más de 6 millones de resultados de las pruebas y más de 4 millones de perfiles individuales de Facebook con una gran variedad de información personal del usuario, como datos demográficos y de geo-localización, gustos, actualizaciones de estado, y las relaciones de amistad, entre otros.

A partir de mayo de 2014 esta aplicación ha permitido registrar una base de datos con 46 millones de “Me Gusta/Likes” de Facebook acerca de los gustos y preferencias de usuario, con 220.000 valoraciones para 5,5 millones de ítems de distinta naturaleza –personas (actores, música, políticos, deportistas, etc.), objetos (películas, libros, juegos, canciones, etc.), organizaciones, eventos, etc.–, así como los valores de los factores FFM de 3.1 millones de usuarios extraídos usando los cuestionarios IPIP de 20 a 336 elementos.

En este trabajo hemos seleccionado únicamente un subconjunto de la base de datos proporcionada debido a su complejidad, centrando la atención de nuestros experimentos en aquellos datos que se corresponden con los “Me Gusta/Likes” de Facebook, o lo que es lo mismo los ratings, asociados a cada ítem perteneciente a las siguientes categorías:

- Géneros cinematográficos (por ejemplo, comedia, drama, acción, bélica, independiente, etc.).
- Géneros musicales (por ejemplo, rock, pop, country, clásica, hip-hop, etc.).
- Géneros literarios (Aventuras, terror, historia, etc.).

Un ejemplo de la selección de datos sería, por ejemplo, aquellos ítems que se correspondiesen con los géneros y categorías (etiquetas) siguientes: *comedia*, *acción*, *drama*, *ciencia-ficción*, *zombies*, *star wars* y *james bond*. Las películas que el usuario selecciona o señala como “preferidas” no se tienen en cuenta en este estudio.

Tras esto, se seleccionan únicamente aquellos usuarios de la base de datos que han proporcionado algún rating o calificación para los ítems considerados. A continuación se realizan operaciones de procesamiento de texto (normalización) para consolidar las posibles derivaciones morfológicas de algunas palabras utilizadas para la clasificación de los ítems (por ejemplo. *ciencia ficción*, *ciencia-ficción*, *sci-fi*, y *sf*).

El conjunto entero de datos contiene en total 22.289 usuarios y 1.748 ítems. La siguiente tabla muestra algunas estadísticas sobre los usuarios, ítems y ratings (calificaciones) en los tres dominios considerados (películas, música y libros) y sus solapamientos:

Dominios	#Usuarios	#Ítems	#Ratings	Dispersión de rating	Solapamiento de usuario
Películas	16,168	268	27.921	99.36%	N/A
Música	17.98	1.175	66.079	99.69%	N/A
Libros	15.251	305	23.882	99.49%	N/A
Películas & Música	22.012	1.443	94	99.70%	55.13%
Películas & Libros	21.41	573	51.803	99.58%	46.75%
Música & Libros	22.029	1.480	89.961	99.72%	50.85%

Tabla 6: Estadísticas del conjunto de datos utilizado.

5.2. Escenarios de preferencias de usuario en dominios cruzados

Dominios individuales

La mayoría de los sistemas de recomendación trabajan con dominios individuales, es decir, recomiendan ítems relacionados con el mismo dominio en el que los usuarios han valorado otros ítems (por ejemplo, a un usuario que haya valorado uno o varios libros se le recomendarán otros según la valoración que haya dado a los primeros) [32].

Las recomendaciones de ítems en el dominio D se generan explotando los rasgos de personalidad y preferencias de usuario dentro éste. Los usuarios de un dominio son aquellos que han expresado sus preferencias (ratings o calificaciones, revisiones, etiquetas, etc.) por los ítems que lo componen. Dichos ítems pueden tener características o atributos que establezcan una relación con el dominio en particular en vez de las preferencias de usuario.

Dominios cruzados con solapamiento

Los SR de dominios cruzados tratan de explotar el conocimiento de los dominios de origen D_S para generar y mejorar las recomendaciones en el dominio de destino D_T . En cualquier caso se pueden considerar más de un dominio de origen.

Correspondiente con el caso de “solapamiento de usuario”, es decir, hay algunos usuarios comunes entre dominios que tienen preferencias en ambos. En este escenario las recomendaciones de ítems en el dominio D_T (destino) se generan explotando las similitudes entre usuarios basadas en los rasgos de personalidad de usuario y/o las preferencias por los ítems en los dominios D_S (origen) y D_T (destino).

Dominios cruzados sin solapamiento

Correspondiente con el caso de “no solapamiento”, es decir, no existe ningún solapamiento entre los usuarios y los ítems en los dominios. En este escenario las recomendaciones de ítems en D_T (destino) se generan explotando las similitudes entre usuarios basadas en los rasgos de personalidad de usuario y/o las preferencias por los ítems únicamente D_S (origen).

5.3. Metodología y métricas de evaluación

En los experimentos llevados a cabo para este Trabajo de Fin de Grado se han comparado 31 métodos divididos de la siguiente manera:

- 1 método basado en el Filtrado Colaborativo que únicamente tiene en cuenta las preferencias de usuario (CF).
- 3 métodos que evalúan exclusivamente la personalidad de usuario (COS-pers, PEA-pers y SPE-pers).
- 27 métodos que evalúan tanto las preferencias de usuario como la personalidad según el valor del parámetro $\lambda = 0.1, 0.2, \dots, 0.9$.

Estos fueron evaluados utilizando los valores de las métricas de precisión (P), recall (R) y F-measure (F) para el **top k** de las recomendaciones (**P@ k** , **R@ k** y **F@ k**), siendo $k = 1, \dots, 5$. Los resultados devueltos son los valores promedio de ejecutar cada métrica 5 veces con el objetivo de ajustar la evaluación lo máximo posible y eliminar errores. Se ha considerado el 80% de los ratings de los usuarios para el dominio destino como parte de entrenamiento y el 20% restante de los datos para la parte de test. Todos los métodos fueron ejecutados con vecindarios de tamaño 5, 10, 15, 20 y 25.

$$P = \frac{|Relevantes \cap Devueltos|}{|Devueltos|} \quad (8)$$

Fórmula 8: Expresión matemática para el cálculo de la Precisión

$$R = \frac{|Relevantes \cap Devueltos|}{|Relevantes|} \quad (9)$$

Fórmula 9: Expresión matemática para el cálculo del Recall

$$F = \frac{2P \cdot R}{P + R} \quad (10)$$

Fórmula 10: Expresión matemática para el cálculo del F-measure

$$m@k(Rel, q) = m(topk(Rel), q) \quad (11)$$

Fórmula 11: Expresión matemática para el cálculo de cualquier métrica m sobre el top k

En todos los escenarios de dominios simples y cruzados los conjuntos de test están compuestos por los ratings o calificaciones de los ítems en el dominio de destino. En el caso de los dominios cruzados **con solapamiento** el valor de la similitud entre usuarios teniendo en cuenta únicamente las preferencias, $sim_{pref}(u, v)$, ha sido calculado utilizando los ratings de los usuarios para ítems en cualquiera de los dominios (origen o destino), eliminándolos del conjunto de test. Para los dominios cruzados **sin solapamiento** $sim_{pref}(u, v)$ ha sido calculada con los ratings pertenecientes al dominio de origen, si necesitar ninguna información del dominio de destino.

6. Resultados de evaluación obtenidos

6.1. Evaluación sobre dominios individuales

Siendo un resultado esperable, en los tres dominios analizados (música, cine y literatura), las versiones puras de los métodos basados en personalidad, es decir, aquellas con $\lambda = 0$, obtienen peores resultados que el método genérico de CF, el cual únicamente emplea las preferencias de usuario en sus cálculos. Sin embargo, si se explota tanto la información sobre personalidad como las preferencias en un método híbrido, éste supera claramente al CF. En estos experimentos la influencia de la personalidad en el dominio del cine es alta ($\lambda = 0.2, 0.3$), media en la literatura ($\lambda = 0.5, 0.7$) y baja en la música ($\lambda = 0.8, 0.9$).

En cuanto a los métodos empleados para establecer la similitud entre usuarios, **PEA** ha sido el que mejores resultados ha tenido para películas y libros, mientras que el método **COS** devuelve los mejores resultados para música.

Las siguientes tablas muestran los resultados obtenidos para cada métrica, método y dominio individual, que reflejan las observaciones anteriores. En negrita se destacan los mejores resultados para las diferentes métricas P@k, R@k F@k, y el promedio de F (Avg. F).

	Method	Neighbors	P@1	P@2	P@3	P@4	P@5	R@1	R@2	R@3	R@4	R@5	F@1	F@2	F@3	F@4	F@5	Avg. F
MOVIES	CF	20	.138	.397	.479	.361	.429	.024	.142	.268	.276	.303	.040	.209	.344	.312	.355	.252
	COS-pers	5	.099	.242	.290	.339	.353	.099	.241	.284	.292	.294	.099	.242	.287	.314	.321	.252
	COS-0.3	15	.154	.400	.488	.463	.460	.024	.119	.242	.306	.291	.041	.183	.323	.368	.355	.254
	PEA-pers	5	.095	.267	.337	.375	.373	.095	.267	.333	.343	.323	.095	.267	.335	.358	.346	.280
	PEA-0.2	10	.178	.442	.466	.439	.372	.071	.236	.350	.340	.314	.102	.308	.400	.383	.340	.307
	SPE-pers	5	.102	.243	.351	.357	.261	.102	.240	.331	.316	.223	.102	.241	.340	.335	.241	.252
	SPE-0.3	10	.177	.431	.430	.474	.491	.052	.185	.307	.341	.310	.081	.259	.358	.396	.379	.295

Tabla 7: Ejecución de recomendaciones de películas en dominio simple

	Method	Neighbors	P@1	P@2	P@3	P@4	P@5	R@1	R@2	R@3	R@4	R@5	F@1	F@2	F@3	F@4	F@5	Avg. F
MUSIC	CF	5	.131	.194	.229	.247	.247	.062	.109	.136	.155	.159	.084	.140	.171	.190	.194	.156
	COS-pers	5	.033	.066	.083	.094	.107	.033	.065	.083	.094	.106	.033	.066	.083	.094	.106	.076
	COS-0.8	5	.135	.197	.238	.248	.247	.069	.120	.151	.167	.172	.092	.149	.184	.200	.203	.166
	PEA-pers	5	.032	.058	.073	.090	.099	.032	.058	.073	.090	.098	.032	.058	.073	.090	.098	.070
	PEA-0.9	5	.131	.194	.234	.244	.255	.067	.115	.149	.167	.184	.089	.145	.182	.199	.213	.166
	SPE-pers	5	.024	.060	.081	.096	.101	.024	.059	.081	.095	.099	.024	.059	.081	.096	.100	.072
	SPE-0.9	5	.130	.193	.227	.241	.241	.067	.115	.145	.163	.177	.088	.144	.177	.194	.204	.162

Tabla 8: Ejecución de recomendaciones de música en dominio simple

	Method	Neighbors	P@1	P@2	P@3	P@4	P@5	R@1	R@2	R@3	R@4	R@5	F@1	F@2	F@3	F@4	F@5	Avg. F
BOOKS	CF	15	.097	.146	.189	.227	.291	.026	.081	.129	.199	.245	.041	.104	.153	.212	.266	.155
	COS-pers	5	.052	.102	.152	.201	.243	.052	.102	.150	.187	.196	.052	.102	.151	.194	.217	.143
	COS-0.1	15	.095	.150	.235	.292	.270	.027	.081	.147	.254	.219	.042	.105	.181	.271	.242	.168
	PEA-pers	5	.057	.124	.181	.212	.236	.057	.123	.172	.197	.213	.057	.123	.177	.204	.224	.157
	PEA-0.7	20	.084	.167	.191	.280	.288	.026	.105	.144	.270	.253	.040	.129	.164	.274	.269	.175
	SPE-pers	5	.040	.105	.170	.164	.218	.040	.104	.169	.158	.197	.040	.105	.170	.161	.206	.136
	SPE-0.5	20	.092	.156	.184	.229	.272	.036	.112	.164	.221	.272	.051	.131	.173	.225	.272	.170

Tabla 9: Ejecución de recomendaciones de libros en dominio simple

6.2. Evaluación sobre dominios cruzados con solapamiento

En general, CF explotando la información acerca de las preferencias de usuario tanto en el dominio de origen como en el de destino obtiene mejores resultados de recomendación que sobre escenarios de dominios individuales y, como se mostrará en sección 6.3, de dominios cruzados sin solapamiento. Los valores obtenidos han sido los siguientes:

	Method	Neighbors	P@1	P@2	P@3	P@4	P@5	R@1	R@2	R@3	R@4	R@5	F@1	F@2	F@3	F@4	F@5	Avg. F
MUSIC & MOVIES	CF	5	.212	.457	.492	.488	.474	.115	.243	.300	.286	.350	.149	.317	.373	.360	.403	.320
	COS-pers	5	.096	.255	.319	.391	.363	.076	.219	.285	.323	.343	.085	.235	.301	.354	.352	.266
	COS-0.1	5	.179	.447	.503	.518	.416	.106	.271	.344	.401	.355	.134	.338	.408	.452	.383	.343
	PEA-pers	5	.097	.259	.340	.359	.361	.077	.223	.307	.327	.298	.086	.240	.323	.342	.326	.263
	PEA-0.6	5	.179	.422	.463	.497	.517	.113	.270	.331	.378	.418	.139	.330	.386	.430	.462	.349
	SPE-pers	5	.107	.257	.344	.397	.295	.084	.220	.295	.316	.258	.094	.237	.318	.351	.275	.255
	SPE-0.2	5	.160	.395	.464	.517	.467	.119	.293	.344	.412	.394	.137	.337	.395	.458	.426	.351

Tabla 10: Ejecución de recomendaciones de películas a partir de las preferencias sobre música en dominios cruzados con solapamiento (&)

	Method	Neighbors	P@1	P@2	P@3	P@4	P@5	R@1	R@2	R@3	R@4	R@5	F@1	F@2	F@3	F@4	F@5	Avg. F
BOOKS & MOVIES	CF	5	.524	.655	.692	.535	.396	.208	.287	.419	.422	.353	.298	.399	.522	.472	.373	.413
	COS-pers	5	.089	.246	.316	.371	.346	.065	.228	.309	.364	.341	.075	.236	.313	.368	.343	.267
	COS-0.7	5	.510	.671	.697	.546	.436	.201	.294	.423	.424	.350	.288	.408	.526	.477	.387	.417
	PEA-pers	5	.089	.246	.316	.371	.346	.065	.228	.309	.364	.341	.075	.236	.313	.368	.343	.267
	PEA-0.8	5	.490	.630	.644	.500	.426	.194	.288	.439	.444	.363	.278	.396	.522	.471	.392	.412
	SPE-pers	5	.091	.262	.348	.397	.287	.067	.241	.325	.343	.236	.077	.251	.336	.368	.259	.258
	SPE-0.5	5	.403	.576	.612	.544	.326	.199	.323	.433	.467	.294	.266	.414	.507	.502	.309	.400

Tabla 11: Ejecución de recomendaciones de películas a partir de las preferencias sobre libros en dominios cruzados con solapamiento (&)

	Method	Neighbors	P@1	P@2	P@3	P@4	P@5	R@1	R@2	R@3	R@4	R@5	F@1	F@2	F@3	F@4	F@5	Avg. F
MOVIES & MUSIC	CF	5	<u>.150</u>	.205	.216	.241	.235	.076	.109	.122	.143	.141	.101	.142	.156	.179	.176	.151
	COS-pers	5	.036	.068	.085	.093	.102	.025	.051	.066	.075	.082	.030	.058	.074	.083	.091	.067
	COS-0.7	5	<u>.150</u>	<u>.207</u>	<u>.223</u>	<u>.242</u>	<u>.238</u>	<u>.083</u>	<u>.120</u>	<u>.135</u>	<u>.153</u>	<u>.155</u>	<u>.107</u>	.152	<u>.169</u>	<u>.187</u>	.188	.161
	PEA-pers	5	.035	.062	.082	.095	.106	.024	.047	.064	.077	.085	.029	.053	.072	.085	.095	.067
	PEA-0.9	5	.147	.199	.218	.225	.235	.082	.115	.133	.147	.156	.105	.146	.165	.178	.187	.156
	SPE-pers	5	.033	.059	.075	.081	.099	.023	.044	.058	.066	.080	.027	.050	.066	.072	.088	.061
	SPE-0.9	5	.145	.201	.217	.222	.236	.081	.117	.134	.146	.161	.104	.147	.165	.176	.192	.157

Tabla 12: Ejecución de recomendaciones de música a partir de las preferencias sobre películas en dominios cruzados con solapamiento (&)

	Method	Neighbors	P@1	P@2	P@3	P@4	P@5	R@1	R@2	R@3	R@4	R@5	F@1	F@2	F@3	F@4	F@5	Avg. F
BOOKS & MUSIC	CF	5	.120	.177	.204	.217	.227	.056	.084	.102	.116	.126	.077	.114	.136	.151	.162	.128
	COS-pers	5	.032	.061	.077	.094	.109	.020	.040	.052	.065	.077	.025	.048	.062	.077	.090	.060
	COS-0.7	5	.124	.177	.206	.210	.238	.063	.091	.113	.125	.141	.084	.120	.146	.157	.177	.137
	PEA-pers	5	.028	.057	.071	.089	.106	.018	.037	.048	.060	.074	.022	.045	.057	.072	.087	.057
	PEA-0.9	5	.118	.170	.206	.215	.225	.061	.088	.112	.128	.141	.081	.116	.145	.161	.173	.135
	SPE-pers	5	.031	.062	.081	.091	.097	.019	.040	.054	.062	.068	.024	.049	.065	.074	.080	.058
	SPE-0.9	5	.117	.172	.204	.210	.227	.061	.089	.114	.124	.140	.080	.117	.146	.156	.173	.134

Tabla 13: Ejecución de recomendaciones de música a partir de las preferencias sobre libros en dominios cruzados con solapamiento (&)

	Method	Neighbors	P@1	P@2	P@3	P@4	P@5	R@1	R@2	R@3	R@4	R@5	F@1	F@2	F@3	F@4	F@5	Avg. F
MOVIES & BOOKS	CF	5	<u>.382</u>	.452	.451	<u>.521</u>	.463	<u>.157</u>	.236	.283	.378	.323	<u>.222</u>	.310	.348	<u>.438</u>	.381	.340
	COS-pers	5	.055	.123	.181	.211	.188	.044	.114	.175	.205	.162	.049	.118	.178	.208	.174	.145
	COS-0.4	5	.381	<u>.468</u>	<u>.458</u>	.518	<u>.488</u>	.152	.238	.288	.367	.369	.217	<u>.315</u>	.353	.430	.420	<u>.347</u>
	PEA-pers	5	.062	.123	.169	.199	.264	.049	.113	.162	.192	.237	.055	.118	.165	.195	.250	.157
	PEA-0.9	5	.381	.454	.428	.499	.477	.149	.232	.292	<u>.374</u>	<u>.380</u>	.214	.307	.347	.428	<u>.423</u>	.344
	SPE-pers	5	.059	.140	.189	.187	.245	.047	.129	.183	.179	.220	.052	.134	.186	.183	.232	.157
	SPE-0.9	5	<u>.382</u>	.462	.446	.518	.420	.149	<u>.239</u>	<u>.303</u>	.340	.330	.214	<u>.315</u>	<u>.361</u>	.410	.370	.334

Tabla 14: Ejecución de recomendaciones de libros a partir de las preferencias sobre películas en dominios cruzados con solapamiento (&)

	Method	Neighbors	P@1	P@2	P@3	P@4	P@5	R@1	R@2	R@3	R@4	R@5	F@1	F@2	F@3	F@4	F@5	Avg. F
MUSIC & BOOKS	CF	10	.098	.140	.172	.236	.364	.064	.091	.122	.187	.273	.078	.110	.142	.208	.311	.170
	COS-pers	5	.053	.107	.147	.176	.217	.041	.087	.126	.161	.166	.046	.096	.136	.168	.188	.127
	COS-0.5	10	.093	.128	.214	.273	.313	.061	.088	.157	.215	.215	.073	.104	.181	.240	.255	.171
	PEA-pers	5	.050	.108	.136	.173	.269	.038	.086	.116	.145	.167	.043	.096	.125	.158	.206	.126
	PEA-0.6	10	.079	.132	.195	.210	.347	.057	.098	.151	.192	.272	.066	.113	.170	.201	.305	.171
	SPE-pers	5	.046	.097	.147	.146	.187	.035	.079	.127	.132	.134	.040	.087	.136	.139	.156	.112
	SPE-0.7	10	.090	.134	.177	.253	.306	.063	.099	.132	.224	.239	.074	.114	.151	.238	.268	.169

Tabla 15: Ejecución de recomendaciones de libros a partir de las preferencias sobre música en dominios cruzados con solapamiento (&)

De acuerdo con los resultados obtenidos, para recomendar películas se puede observar que se obtienen valores más altos para las métricas si se usan las preferencias sobre el dominio de los libros que si lo hacemos con las preferencias en música. Sin embargo, para recomendar música se han obtenido mejores resultados al utilizar las preferencias sobre películas.

En el caso de recomendación con solapamiento el método **COS** ofrece un mejor rendimiento que los métodos **PEA** y **SPE** como puede observarse en las siguientes tablas. Los valores más altos se han obtenido utilizando un vecindario de tamaño **5**.

6.3. Evaluación sobre dominios cruzados sin solapamiento

Este tipo de escenario es el más complejo, ya que las recomendaciones sobre ítems en un dominio destino requieren que no se utilice ningún tipo de información acerca de las preferencias de usuario en ese dominio, sino de otro dominio origen. Por lo tanto, tal y como cabe esperar tras la definición de “no solapamiento” entre dominios, el rendimiento obtenido es inferior al del caso anterior con solapamiento. Los resultados obtenidos se pueden ver en las siguientes tablas:

	Method	Neighbors	P@1	P@2	P@3	P@4	P@5	R@1	R@2	R@3	R@4	R@5	F@1	F@2	F@3	F@4	F@5	Avg. F
MUSIC → MOVIES	CF	5	.107	.323	.411	.384	.452	.085	.275	.366	.334	.384	.095	.297	.387	.357	.415	.310
	COS-pers	5	.095	.256	.316	.369	.350	.075	.220	.285	.311	.330	.084	.237	.300	.338	.340	.260
	COS-0.1	5	.111	.318	.411	.466	.422	.088	.270	.339	.369	.361	.098	.292	.372	.412	.389	.313
	PEA-pers	5	.097	.263	.335	.361	.354	.077	.226	.301	.323	.288	.086	.243	.317	.341	.317	.261
	PEA-0.5	5	.112	.327	.417	.479	.540	.089	.278	.347	.369	.462	.099	.300	.379	.416	.497	.338
	SPE-pers	5	.107	.256	.335	.387	.280	.085	.220	.290	.303	.242	.095	.236	.311	.340	.260	.248
	SPE-0.1	5	.115	.318	.396	.452	.402	.091	.270	.337	.403	.391	.102	.292	.364	.426	.396	.316

Tabla 16: Ejecución de recomendaciones de películas a partir de las preferencias sobre música en dominios cruzados sin solapamiento (→)

	Method	Neighbors	P@1	P@2	P@3	P@4	P@5	R@1	R@2	R@3	R@4	R@5	F@1	F@2	F@3	F@4	F@5	Avg. F
BOOKS → MOVIES	CF	5	.264	.496	.543	.441	.400	.191	.419	.482	.395	.377	.221	.454	.511	.417	.388	.398
	COS-pers	5	.088	.247	.318	.377	.354	.064	.228	.312	.373	.349	.074	.237	.315	.375	.351	.270
	COS-0.1	5	.243	.464	.528	.498	.420	.175	.403	.476	.439	.402	.203	.431	.501	.467	.410	.403
	PEA-pers	5	.102	.281	.352	.350	.347	.075	.262	.339	.322	.281	.087	.271	.345	.335	.311	.270
	PEA-0.5	5	.238	.464	.553	.504	.441	.171	.402	.489	.449	.422	.199	.431	.519	.475	.431	.411
	SPE-pers	5	.091	.263	.353	.365	.278	.066	.242	.333	.326	.235	.077	.252	.342	.345	.255	.254
	SPE-0.9	5	.243	.473	.528	.514	.454	.175	.410	.462	.440	.378	.203	.439	.493	.474	.412	.404

Tabla 17: Ejecución de recomendaciones de películas a partir de las preferencias sobre libros en dominios cruzados sin solapamiento (→)

	Method	Neighbors	P@1	P@2	P@3	P@4	P@5	R@1	R@2	R@3	R@4	R@5	F@1	F@2	F@3	F@4	F@5	Avg. F
MOVIES → MUSIC	CF	5	.036	.063	.082	.095	.113	.023	.042	.057	.070	.083	.028	.051	.067	.081	.096	.065
	COS-pers	5	.035	.067	.086	.094	.103	.025	.050	.067	.076	.083	.029	.058	.075	.084	.092	.068
	COS-0.1	5	.037	.068	.092	.101	.118	.026	.051	.072	.081	.095	.031	.058	.081	.090	.105	.073
	PEA-pers	5	.036	.062	.083	.095	.107	.025	.046	.065	.077	.086	.029	.053	.073	.085	.095	.067
	PEA-0.6	5	.040	.069	.086	.097	.118	.028	.052	.066	.078	.095	.033	.059	.075	.086	.105	.072
	SPE-pers	5	.033	.061	.074	.082	.098	.023	.045	.058	.067	.079	.027	.052	.065	.074	.087	.061
	SPE-0.3	5	.039	.072	.090	.103	.116	.027	.054	.070	.083	.093	.032	.062	.079	.092	.103	.074

Tabla 18: Ejecución de recomendaciones de música a partir de las preferencias sobre películas en dominios cruzados sin solapamiento (→)

	Method	Neighbors	P@1	P@2	P@3	P@4	P@5	R@1	R@2	R@3	R@4	R@5	F@1	F@2	F@3	F@4	F@5	Avg. F
BOOKS → MUSIC	CF	5	.027	.056	.081	.090	.102	.016	.033	.049	.056	.065	.020	.041	.061	.069	.080	.054
	COS-pers	5	.032	.062	.077	.097	.109	.021	.040	.052	.066	.078	.025	.049	.062	.079	.091	.061
	COS-0.1	5	.034	.064	.086	.100	.122	.022	.041	.058	.068	.085	.026	.050	.069	.081	.100	.065
	PEA-pers	5	.029	.057	.072	.089	.104	.018	.037	.048	.061	.074	.022	.045	.058	.072	.087	.057
	PEA-0.3	5	.036	.064	.086	.102	.123	.023	.042	.058	.070	.086	.028	.050	.069	.083	.102	.066
	SPE-pers	5	.030	.063	.081	.090	.098	.019	.041	.055	.061	.069	.024	.049	.065	.073	.081	.058
	SPE-0.2	5	.036	.064	.082	.102	.124	.023	.042	.055	.069	.086	.028	.050	.065	.082	.102	.066

Tabla 19: Ejecución de recomendaciones de música a partir de las preferencias sobre libros en dominios cruzados sin solapamiento (→)

	Method	Neighbors	P@1	P@2	P@3	P@4	P@5	R@1	R@2	R@3	R@4	R@5	F@1	F@2	F@3	F@4	F@5	Avg. F
MOVIES → BOOKS	CF	5	.091	.235	.304	.370	.352	.071	.205	.271	.346	.350	.080	.219	.287	.357	.351	.259
	COS-pers	5	.056	.121	.174	.205	.221	.045	.112	.168	.199	.186	.050	.117	.171	.202	.202	.148
	COS-0.1	5	.115	.244	.321	.381	.393	.089	.212	.277	.344	.326	.100	.227	.297	.361	.356	.268
	PEA-pers	5	.060	.124	.165	.202	.257	.048	.114	.160	.195	.237	.054	.119	.163	.198	.246	.156
	PEA-0.5	5	.121	.248	.303	.358	.407	.093	.214	.252	.319	.312	.105	.230	.275	.337	.353	.260
	SPE-pers	5	.061	.141	.187	.194	.260	.048	.130	.181	.186	.230	.054	.136	.184	.190	.244	.162
	SPE-0.6	5	.115	.259	.318	.359	.475	.089	.227	.273	.335	.418	.100	.242	.294	.346	.445	.285

Tabla 20: Ejecución de recomendaciones de libros a partir de las preferencias sobre películas en dominios cruzados sin solapamiento (→)

	Method	Neighbors	P@1	P@2	P@3	P@4	P@5	R@1	R@2	R@3	R@4	R@5	F@1	F@2	F@3	F@4	F@5	Avg. F
MUSIC → BOOKS	CF	5	.067	.142	.163	.211	.297	.051	.113	.137	.191	.215	.057	.126	.149	.200	.250	.156
	COS-pers	5	.053	.107	.147	.185	.196	.041	.086	.127	.169	.145	.046	.096	.136	.177	.166	.124
	COS-0.3	5	.065	.125	.165	.227	.296	.049	.098	.133	.205	.227	.056	.110	.147	.215	.257	.157
	PEA-pers	5	.051	.109	.139	.173	.274	.039	.087	.121	.146	.183	.044	.097	.130	.158	.219	.130
	PEA-0.3	5	.071	.121	.180	.221	.286	.054	.097	.156	.206	.230	.061	.107	.167	.213	.255	.161
	SPE-pers	5	.047	.097	.149	.131	.183	.035	.079	.130	.116	.130	.040	.087	.139	.123	.152	.108
	SPE-0.1	5	.071	.115	.171	.238	.319	.054	.090	.142	.215	.261	.062	.101	.155	.226	.287	.166

Tabla 21: Ejecución de recomendaciones de libros a partir de las preferencias sobre música en dominios cruzados sin solapamiento (→)

Si se observan los resultados obtenidos para los dominios del cine y la literatura a partir de los métodos que tienen en cuenta la personalidad, estos son mejores que el método CF original que únicamente explota la información acerca de las preferencias de usuario en el dominio de destino.

Al igual que en los dominios individuales, esto puede deberse a que el promedio de ratings o calificaciones aportadas por los usuarios son mayores en el dominio de la música que en el de los libros y las películas. CF explota mejor las similitudes de usuarios basándose en sus preferencias, pero el beneficio de emplearlo para mejorar las recomendaciones utilizando la información de la personalidad es menor.

A diferencia de los escenarios anteriores, en este caso los métodos **PEA** y **SPE** obtienen resultados más óptimos que COS. En este caso el tamaño del vecindario para un rendimiento óptimo es 5.

6.4. Discusión

En nuestro experimento se ha considerado que todos los factores que determinan la personalidad (FFM) tienen la misma relevancia para estimar y explotar la similitud entre usuarios basada en personalidad en un contexto de filtrado colaborativo. Sin embargo, como se ha expuesto a lo largo del trabajo, revisando el estado de la cuestión, se ha demostrado que la personalidad, más concretamente sus factores, influyen de manera distinta en las preferencias de usuario hacia determinados ítems, lo que hace de esta relación un tema interesante para su estudio.

El conjunto de datos utilizado comprende la información acerca de las preferencias de los ítems según si el usuario selecciona “Me Gusta/Like” en los géneros de cada dominio; esto implica utilizar la similitud de Jaccard en la estrategia de la heurística basada en el método de Filtrado Colaborativo para la generación del top N de recomendaciones. En el caso de que los usuarios dispusiesen de una opción binaria para calificar los ítems de cada dominio seleccionando “Me Gusta” o “No Me Gusta” según procediese, o lo hiciesen a través de un valor numérico (rating), y esta información estuviese disponible como preferencias de usuario, se podrían investigar métodos de filtrado colaborativo más elaborados (basados en PEA y SPE) para la generación del top N y la predicción de los ratings.

Además de las métricas empleadas (precisión, recall y F-measure) para la evaluación del top N de recomendaciones, ampliamente usadas por los usuarios, serían posibles otros enfoques para el estudio de la relación entre las preferencias de usuario y la personalidad, como por ejemplo:

- El uso de las **facetas** de la personalidad (por ejemplo, cordialidad, gregarismo, fantasía, sentimientos, orden, confianza, modestia, etc.) en lugar de los factores FFM.
- La medida de la **diversidad** en las recomendaciones (por ejemplo, las personas con un alto valor de OPE tienden a tener preferencia por tipos de ítems más diversos).
- Análisis de las preferencias de usuario según su **género** y **edad**. Esto podría contribuir a la generación de recomendaciones más personalizadas.

7. Conclusiones y trabajo futuro

En este trabajo se han presentado una serie de métodos de Filtrado Colaborativo que tienen en cuenta la personalidad del usuario, y se han evaluado en diferentes dominios (música, cine y literatura) de manera individual y cruzada sobre un gran conjunto de datos extraídos de la red social Facebook. Dado que en la actualidad se trata de la red social con mayor número de perfiles y mayor actividad diaria, la información contenida en la base de datos refleja en gran medida los gustos y preferencias que tienen los usuarios a día de hoy.

Los resultados obtenidos de manera empírica han demostrado que efectivamente los métodos propuestos mejoran el comportamiento de las métricas de precisión y recall en los dominios analizados. Por lo tanto, este trabajo supone un paso más allá en la generación de recomendaciones mediante el estudio de la información sobre la personalidad del usuario. Puede considerarse como futuro método para generar recomendaciones más exitosas, eliminando posiblemente un grueso de ítems que no serían de interés para el usuario pero que sin embargo se le recomiendan por la información que se tiene de otros usuarios afines o con preferencias similares a las suyas.

Aunque los resultados obtenidos han sido positivos, estos métodos deberían integrarse y compararse con otros FC más elaborados. Además, se deberían evaluar en la predicción de la calificación o rating que un usuario aportaría a un determinado ítem según su personalidad, y observar qué métricas distintas a la precisión y el recall aportarían los mejores resultados.

Como ya se comentó al final del apartado de discusión de resultados, podrían plantearse en el futuro otros enfoques para mejorar la recomendación personalizada como el estudio de las diferentes facetas de personalidad que tratan de deducirse de cada uno de los factores del FFM, la diversidad de ítems entre distintos dominios que pueden ser de interés para los usuarios, y la relación entre las preferencias y la personalidad en función del sexo o el rango de edad al que pertenece el usuario.

El código implementado para la realización del experimento de este trabajo utiliza librerías y software libre, como es el caso de Mahout, para la evaluación de los métodos propuestos. Esto ha ahorrado tiempo y esfuerzo de desarrollo, lo que es muy útil a la hora de seguir investigando en el tema.

Referencias

- [1] E. Herrera-Viedma, C. Porcel y L. Hidalgo, «HIPERTEXT.NET - Sistemas de recomendaciones: herramientas para el filtrado de información en Internet» 6 Mayo 2012. [En línea]. Available: <http://www.upf.edu/hipertextnet/numero-2/recomendacion.html>. [Último acceso: 25 Diciembre 2013].
- [2] L. leGrey, «Wikipedia - Sistema de Recomendación» 12 Junio 2009. [En línea]. Available: http://es.wikipedia.org/w/index.php?title=Sistema_de_recomendaci%C3%B3n&action=history. [Último acceso: 25 Diciembre 2013].
- [3] I. Cantador, I. Fernández-Tobías y I. Bellogín, «Relating Personality Types with User Preferences in Multiple Entertainment Domains» pp. 1-2.
- [4] H. I. Chang Miranda, L. A. Díaz Viejo y F. D. Ruiz Moncayo, «Sistema de predicción y recomendación personalizada basada en ranking de ítems homogéneos usando filtrado colaborativo» Guayaquil, Ecuador, 2006.
- [5] M. Balabanović y Y. Shoham, «Content- Based, Collaborative Recommendation» *Communications of the ACM*, vol. 40, n° 3, pp. 66-72, Marzo 1997.
- [6] I. Fernández-Tobías y I. Cantador, «Personality-aware Collaborative Filtering: An Empirical Study in Multiple Domains with Facebook Data» de *EC-Web 2014*, Múnich, 2014.
- [7] M. Tkalcic, B. De Carolis, M. De Gemmis, A. Odic y A. Kosir, «Emotions and Personality in Personalized Services» de *ACM Conference on Recommender Systems (RecSys '12)*, Dublín, 2012.
- [8] Wikipedia, «Wikipedia - Modelo de los Cinco Grandes» [En línea]. Available: http://es.wikipedia.org/wiki/Modelo_de_los_cinco_grandes. [Último acceso: 20 Enero 2014].
- [9] Desmarina, «Wordpress» Agosto 2006. [En línea]. Available: <http://psicodilema.wordpress.com/2009/09/30/teoria-de-la-personalidad-big-five/>. [Último acceso: 20 Enero 2014].
- [10] K. N, «El Rincón del Vago» [En línea]. Available: http://html.rincondelvago.com/psicologia-de-la-personalidad_el-modelo-de-los-cinco-factores.html. [Último acceso: 20 Enero 2014].
- [11] S. C. Cloninger, «Rasgos de personalidad» de *Teorías de la personalidad*, Tercera edición ed., México, Pearson Educación, 2003, pp. 204-208.
- [12] «Psicología-Online» [En línea]. Available: <http://www.psicologia-online.com/pir/la-teoria-de-cattell.html>. [Último acceso: 21 Enero 2014].
- [13] L. Hernangómez Criado y C. Fernández Belinchón, «Otros modelos de personalidad: Cinco grandes y otros modelos factoriales» de *Psicología de la personalidad y*

diferencial, Segunda edición ed., CEDE, Ed., 2012, pp. 79-81.

- [14] D. Hellriegel y J. W. Slocum, *Organizational Behavior*, 13 ed., South-Western Cengage Learning, 2010, p. 564.
- [15] O. P. John y S. Srivastava, *The Big-Five Trait Taxonomy: History, Measurement, and Theoretical Perspectives*, Berkeley, California, 1999, p. 71.
- [16] F. Ricci, L. Rokach y B. Saphira, *Recommender Systems Handbook*, Springer, 2011, pp. 1-35.
- [17] S. Saral y D. Walker, «Identifying Influential and Susceptible Members of Social Networks» *Science*, vol. 337, 20 Julio 2012.
- [18] R. Moya y R. Invarato, «Jarroba.com» 21 Julio 2013. [En línea]. Available: <http://jarroba.com/que-son-los-sistemas-de-recomendacion/>. [Último acceso: 26 Junio 2014].
- [19] L. Chen, W. Wu y L. He, «How personality influences users' needs for recommendation diversity?» de *CHI '13 Extended Abstracts on Human Factors in Computing Systems*, París, 2013.
- [20] G. Carrillo y X. Ochoa, «Recomendación de objetos de aprendizaje basada en el perfil del usuario y la información de atención contextualizada» de *LACLO 2013 - Octava Conferencia Latinoamericana de Objetos y Tecnologías de Aprendizaje*, Valdivia, Chile, 2013.
- [21] Á. Castellanos, «Recomendación de Contenidos Digitales basados en divergencias del lenguaje» Madrid, 2013.
- [22] V. Gómez, «Sistemas de Recomendación: Filtrado Colaborativo» Leganés, 2012.
- [23] I. Fernández-Tobías y I. Cantador, «Personality-aware Collaborative Filtering: Enhancing Single- and Cross-domain Recommendations» de *RecSys 2014*, Silicon Valley, 2014.
- [24] I. Fernández-Tobías y I. Cantador, «Sistemas de recomendación sobre dominios cruzados: Una revisión del estado del arte,» pp. 1-2.
- [25] P. J. Rentfrow y S. D. Gosling, «The Do Re Mi's of Everyday Life: The Structure and Personality» *Journal of Personality and Social Psychology*, vol. 84, nº 6, 20003.
- [26] S. M. McNee, J. Riedl y J. A. Konstan, «Being accurate is not enough: How accuracy metrics have hurt recommender systems» de *CHI '06 Extended Abstracts on Human Factors in Computing Systems*, Nueva York, 2006.
- [27] Institute of Technology Tallaght, «ITT Dublin» [En línea]. Available: <http://www.it-tallaght.ie/personalitybasedrecommendation>. [Último acceso: 26 Enero 2014].
- [28] L. Betarte, R. Machado y V. Molina, «PGMúsica» Montevideo, 2005 - 2006.
- [29] M. A. Nunes y R. Hu, «Personality-based Recommender Systems: An Overview» de

ACM Conference on Recommender Systems (RecSys'12), Dublín, 2012.

- [30] R. Hu y P. Pu, «Acceptance Issues of Personality-based,» de *ACM Conference on Recommender Systems (RecSys'12)*, Dublín, 2012.
- [31] R. Hu y P. Pu, «Enhancing Collaborative Filtering Systems with Personality Information» de *Proc. of the 5th ACM Conference on Recommender Systems*, 2011.
- [32] P. Cremonesi, A. Tripodi y R. Turrin, «Cross-Domain Recommender Systems» de *IEEE 11th International Conference on Data Mining Workshops (ICDMW)*, 2011, Vancouver, 2011.
- [33] F. Scholten, «TRIFORKblog - Mahout - Taste» 9 Diciembre 2009. [En línea]. Available: <http://blog.trifork.com/2009/12/09/mahout-taste-part-one-introduction/>. [Último acceso: 4 Julio 2014].
- [34] J. García Martínez, M. Garrido Fernández y L. Rodríguez Franco, *Personalidad, procesos cognitivos y psicoterapia: un enfoque constructivista*, Editorial Fundamentos, 1998, pp. 137-138.
- [35] M. Tkalcic, M. Kunaver, A. Kosir y J. Tasic, «Addressing the New User Problem with a Personality Based User Similarity Measure» de *5th Workshop on Emotion in Human-Computer Interaction-Real World Challenges*, 2009.
- [36] R. Hu y P. Pu, «Using Personality Information in Collaborative Filtering for New Users,» de *Recommender Systems and the Social Web*, 2010.
- [37] M. Tkalcic y L. Chen, «Personality and Recommender System» de *RecSys 2010 - ACM Recommender Systems*, Barcelona, 2010.

Anexo A. Librería de sistemas de recomendación Apache Mahout - Taste

La librería Apache-Mahout¹⁴ es un proyecto de la Fundación Apache formado por un conjunto de librerías de código abierto para utilizar técnicas de aprendizaje automático.

En este trabajo se ha utilizado esta librería para el proceso de recomendación, ya que se usan acciones sociales realizadas por los usuarios sobre los objetos de aprendizaje (los usuarios indican sus preferencias haciendo click en el link “Me Gusta/Like” que tienen disponible todos los ítems de la colección), con el objetivo de recomendar ítems al usuario que aún no haya calificado.

Para la generación de recomendaciones con CF usando Mahout se deben seguir los siguientes pasos [20]:

1. Proporcionar el modelo de datos: archivo de texto que contiene las preferencias de usuario respecto a los ítems que servirán como objetos de aprendizaje. Cada línea del fichero tiene la siguiente estructura:
<id_usuario>, <id_item>, <rating>
2. Seleccionar el método (algoritmo) de similitud entre usuarios (COS, PEA, SPE). Mahout implementa estos y otros algoritmos.
3. Indicar el tamaño del vecindario del usuario *u* para determinar los usuarios que tengan las mismas preferencias que él y obtener mejores recomendaciones.
4. Inicializar el SR especificando el modelo de datos, el vecindario y el método (algoritmo) de similitud.
5. Al indicar el **<id_usuario>** se obtiene una lista de ítems recomendados.

Un ejemplo de uso de la librería de Mahout sería para FC sería [20]:

```
//1. Modelo de datos
FileDataModel modelo = new FileDataModel(new File(ficheroOrigen));

//2. Método de similitud (PEA)
UserSimilarity similitud = new PearsonCorrelationSimilarity(modelo);

//3. Vecindario
UserNeighborhood vecindario = new NearestUserNeighborhood(5,similitud,modelo);

//4. Inicialización del SR
Recommender sr = new GenericUserBasedRecommender(modelo,vecindario,similitud);

//5. Generación de recomendaciones
List<RecommendedItem> recomendaciones = sr.recommend(idUsuario,numItems);
```

Es totalmente necesario que el fichero que contiene la información acerca de las preferencias de usuario (*sourcefile*) incluya al menos una entrada con información sobre el usuario al que se va a realizar la recomendación.

Por otra parte, Mahout incluye el paquete **org.apache.mahout.cf.taste.eval** que evalúa los resultados obtenidos y permite examinar su calidad. El paquete **Taste** está formado por

¹⁴ <https://mahout.apache.org/>

herramientas que contienen un porcentaje de los datos utilizados en la parte de test. Cuenta con varios algoritmos de aprendizaje automático escalables. Es un sub-framework de Mahout para la construcción de motores recomendadores [33].

El principal bloque de construcción de Taste es el Recomendador, que sugiere ítems en función de otro determinado o determina usuarios con preferencias similares. Su funcionamiento es el siguiente:

1. El recomendador aplica una función de similitud a un subconjunto de pares de ítems (o usuarios) pertenecientes al conjunto de datos.
2. La función de similitud normalmente devuelve un valor entre 0 y 1, donde 1 representa dos ítems/usuarios totalmente similares y 0 ítems/usuarios completamente diferentes.
3. Cuando la función de similitud procesa pares en el conjunto de datos se recogen los valores de similitud resultantes se mantienen en memoria o almacenan en el sistema de archivos o una base de datos.
4. Cuando la aplicación Java solicita recomendaciones para un elemento dado, el recomendador devuelve los elementos con mayor valor de similitud.

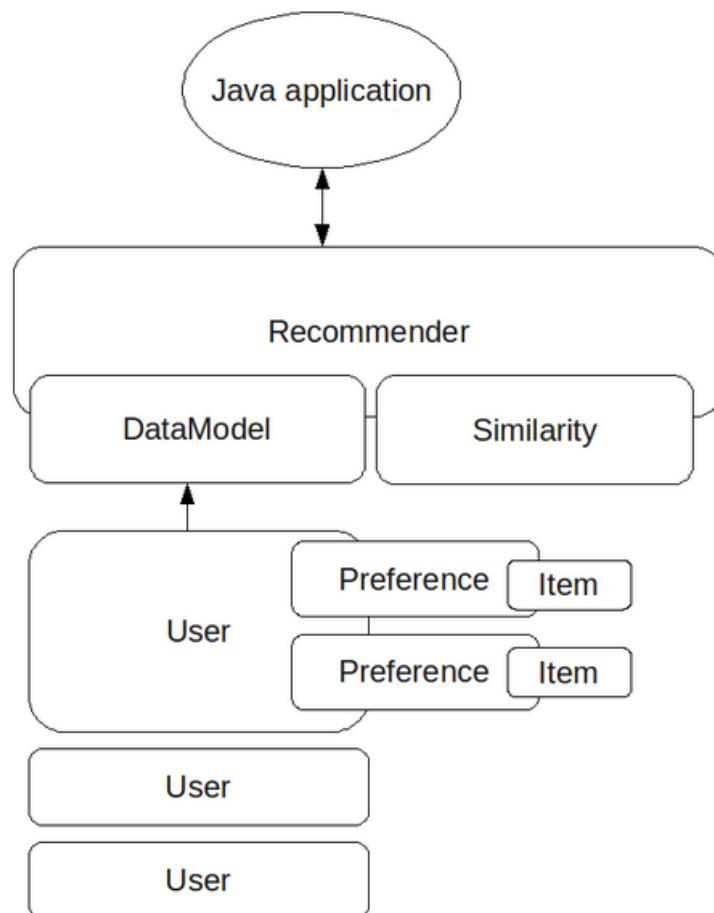


Ilustración 6: Esquema de la arquitectura de Taste [33]

Anexo B. Ejemplo de implementación de similitud entre usuarios

Para este trabajo se ha implementado un SR por cada escenario propuesto (dominios individuales, dominios cruzados con solapamiento y dominios cruzados sin solapamiento) utilizando los datos extraídos de la aplicación myPersonality de la red social de Facebook:

- **FacebookSR**: CF que realiza recomendaciones sobre dominios individuales.
- **CDOverlapFacebookSR**: CF que realiza recomendaciones sobre dominios cruzados con solapamiento.
- **CDNonOverlapFacebookSR**: CF que realiza recomendaciones sobre dominios cruzados sin solapamiento.

En cada una de estas clases se ha creado un main que recibe los siguientes parámetros:

FacebookSR	CDOverlapFacebookSR	CDNonOverlapFacebookSR
- dominio (D)	- dominio origen (D_S) - dominio destino (D_T)	- dominio origen (D_S) - dominio destino (D_T)

Utilizando un array que contiene cada uno de los tamaños de los vecindarios (5, 10, 15, 20) con los que se va a ejecutar cada método de similitud (COS, PEA y SPE), se crea el SR dentro de un bucle que recorre los valores de λ dentro del rango $[0, \dots, 1]$ para abarcar todos los casos (CF, $-\lambda$, $-\text{pers}$), con incrementos de 0.1. El modelo de datos se obtiene de los ficheros de ratings de los que se disponen para cada dominio D .

El siguiente pseudocódigo muestra el proceso de creación de un SR usando dominios individuales:

```
FacebookSR sr = new FacebookSR;
Para cada tam_vecindario:
    Para cada  $\lambda \in [0, \dots, 1]$ ,  $\lambda += 0.1$ :
        RecommenderBuilder srBuilder = sr.getSRCoseno(tam_vecindario,  $\lambda$ );
        sr.evalua(srBuilder, ratings( $D$ ), outFile,  $D$ , tam_vecindario,  $\lambda$ );
```

Los resultados obtenidos se escriben en un fichero de salida (*outFile*) para hacer más fácil su análisis utilizando hojas de cálculo.

El método *getSRCoseno* contiene los pasos explicados en el anexo anterior para CF utilizando la librería Mahout-Taste. En el ejemplo anterior se ha supuesto que el método de similitud a calcular era COS. El pseudocódigo para cada evaluar las similitudes de usuarios según COS, PEA y SPE es el siguiente:

```
double getSim_XXX (userID1, userID2){
    xPrefs = modelo.getItemIDsFromUser(userID1);
    yPrefs = modelo.getItemIDsFromUser(userID2);
    int intersection = xPrefs.intersectionSize(yPrefs);
    int union = xPrefs.size() + yPrefs.size() - intersectionSize;
    simPrefs = (double) intersection / (double) union;
    double simPers = calculaSimPers(userID1, userID2);
    double sim = lambda * simPrefs + (1.0 - lambda) * simPers;
    return sim;
}
```

Donde XXX se corresponde con cada método de similitud. Al ejecutar este método se combina linealmente $sim_{pref}(userID1, userID2)$ con $sim_{pers}(userID1, userID2)$, es decir, las similitudes entre las **preferencias** de los usuarios $userID1$ y $userID2$ con las similitudes entre su **personalidad** según la fórmula 4 (Función de estimación de ratings en CF). Para calcular la similitud entre las personalidades de ambos usuarios $sim_{pers}(userID1, userID2)$ el método anterior hace una llamada a *calculaSimPers* que realiza los cálculos oportunos según el método de similitud elegido:

- **COS:**

```
double calculaSimPers (userID1, userID2){
    ArrayList<Double> user1 = this.userPersonalities.get(userID1);
    ArrayList<Double> user2 = this.userPersonalities.get(userID2);
    double sim = 0, mod1=0, mod2=0;

    for (int i = 0; i < 5; i++) {
        mod1 += user1.get(i) * user1.get(i);
        mod2 += user2.get(i) * user2.get(i);
        sim += user1.get(i) * user2.get(i);
    }

    mod1 = Math.sqrt(mod1);
    mod2 = Math.sqrt(mod2);
    sim /= mod1 * mod2;
    return sim;
}
```

Este método calcula la similitud según la fórmula 5 (Similitud de usuarios teniendo en cuenta la personalidad basada en el coseno, COS.). Los *ArrayList* *user1* y *user2* contendrán los valores de los factores FFM obtenidos del *HashMap* *userPersonalities* que tiene la siguiente estructura:

<Long, ArrayList<Double>>

que se corresponde con el id del usuario y la lista de valores de los factores FFM.

- **PEA:**

```
double calculaSimPers (userID1, userID2){
    ArrayList<Double> user1 = userPersonalities.get(userID1);
    ArrayList<Double> user2 = userPersonalities.get(userID2);
    Double[] aux1 = user1.toArray(new Double[user1.size()]);
    Double[] aux2 = user2.toArray(new Double[user2.size()]);
    double[] x = new double[aux1.length];
    double[] y = new double[aux2.length];
    double sim = 0.0;

    for (int i = 0; i < user1.size(); i++) {
        x[i] = user1.get(i);
        y[i] = user2.get(i);
    }

    sim = PearsonCorrelation.compute(x, y);

    return sim;
}
```

Este método a su vez llama al método de la clase *PearsonCorrelation* que calcula el coeficiente de correlación de Pearson según la fórmula 6 (Similitud de usuarios teniendo en

cuenta la personalidad basada en el coeficiente de correlación de Pearson, PEA.), a partir de dos listas de doubles que contienen los valores de los factores FFM.

- **SPE:**

```
double calculaSimPers (userID1, userID2){
    ArrayList<Double> user1 = userPersonalities.get(userID1);
    ArrayList<Double> user2 = userPersonalities.get(userID2);
    Double[] aux1 = user1.toArray(new Double[user1.size()]);
    Double[] aux2 = user2.toArray(new Double[user2.size()]);
    double[] x = new double[aux1.length];
    double[] y = new double[aux2.length];
    double sim = 0.0;

    for (int i = 0; i < user1.size(); i++) {
        x[i] = user1.get(i);
        y[i] = user2.get(i);
    }

    sim = SpearmanCorrelation.compute(x, y);

    return sim;
}
```

Análogamente al método de Pearson, a partir de dos arrays con los valores de los factores FFM, utilizando el método *compute* de la clase *SpearmanCorrelation* se calculará el coeficiente de correlación de Spearman según la fórmula 7 (Similitud de usuarios teniendo en cuenta la personalidad basada en el coeficiente de correlación de Spearman, SPE.).

Por último, una vez calculadas las similitudes entre usuarios teniendo en cuenta la personalidad y las preferencias se procederá a evaluar las métricas de precisión y recall en el top 5 de las recomendaciones, para ello se ejecuta el método *evalua* de la clase FacebookSR. Este método ejecuta en un bucle de cinco repeticiones, un evaluador perteneciente a la librería Mahout-Taste. Dicho evaluador consiste en una interfaz que cuenta con varios métodos que devuelven las métricas utilizadas más frecuentemente. Entre estos se encuentran *getPrecision*, *getRecall* y *getF1Measure* que devuelve el promedio de F.

En el caso de los CF sobre dominios cruzados la primera diferencia de código con respecto a la implementación sobre dominios individuales se encuentra en la llamada al método que construye el SR, donde ahora, además del tamaño del vecindario y el valor de λ , se deberá indicar el nombre del fichero que contiene los ratings del dominio de origen D_S :

```
RecommenderBuilder srBuilder = sr.getSRCoseno(ratings( $D_S$ ),tam_vecindario, $\lambda$ );
```

De esta manera se construye el modelo de datos que servirán a la parte de entrenamiento para la generación de la recomendación. A continuación, para evaluar las métricas P@k y R@k se deberá indicar en el método *evalua* el fichero que contiene los ratings del dominio de destino D_T y el nombre de ambos dominios D_S y D_T , además del tamaño del vecindario y el valor de λ como en el caso de los dominios individuales:

```
sr.evalua(srBuilder,ratings( $D_T$ ),outFile, $D_S$ , $D_T$ ,tam_vecindario, $\lambda$ );
```

El resto de operaciones de cálculo de similitudes, COS, PEA, SPE y métricas estadísticas se han implementado de igual manera que en el caso de los dominios individuales.

